Universidad Nacional Mayor de San Marcos

Universidad del Perú. Decana de América

Dirección General de Estudios de Posgrado

Facultad de Ingeniería Industrial

Unidad de Posgrado

Aplicación de modelos condicionados a su pasado para pronosticar los precios de las acciones de Telefónica cotizadas en la New York Stock Exchange (NYSE)

TESIS

Para optar el Grado Académico de Doctor en Gestión de Empresas

AUTOR

Wilfredo BAZÁN RAMÍREZ

ASESOR

Dr. Alfonso Ramón CHUNG PINZÁS

Lima, Perú

2021

Referencia bibliográfica

Bazán, W. (2021). *Aplicación de modelos condicionados a su pasado para pronosticar los precios de las acciones de Telefónica cotizadas en la New York Stock Exchange (NYSE)*. [Tesis de doctorado, Universidad Nacional Mayor de San Marcos, Facultad de Ingeniería Industrial, Unidad de Posgrado]. Repositorio institucional Cybertesis UNMSM.

Hoja de metadatos complementarios

Código ORCID del autor	0000-0002-2685-8254
DNI o pasaporte del autor	09415344
Código ORCID del asesor	0000-0002-8073-2396
DNI o pasaporte del asesor	09394397
Grupo de investigación	"__"
Agencia financiadora	"__"
Ubicación geográfica donde se desarrolló la investigación	Lugar Perú, Lima, Lima, FII – UNMSM. Coordenadas geográficas. -12.059489234384964, -77.08114360256927
Año o rango de años en que se realizó la investigación	2000-2018
Disciplinas OCDE	Ingeniería Industrial http://purl.org/pe-repo/ocde/ford#2.11.04

UNIVERSIDAD NACIONAL
MAYOR DE SAN MARCOS
Universidad del Perú, DECANA DE AMERICA

UNIDAD DE POSGRADO

ACTA DE SUSTENTACIÓN VIRTUAL Nº03-UPG-FII-2021

SUSTENTACIÓN DE TESIS VIRTUAL PARA OPTAR EL GRADO ACADÉMICO DE DOCTOR EN GESTIÓN DE EMPRESAS

En la ciudad de Lima, del día 8 del mes de febrero del dos mil veintiuno, siendo las diez horas, de forma virtual se instaló el Jurado Examinador para la Sustentación de la Tesis titulada: **"APLICACIÓN DE MODELOS CONDICIONADOS A SU PASADO PARA PRONOSTICAR LOS PRECIOS DE LAS ACCIONES DE TELEFÓNICA COTIZADAS EN LA NEW YORK STOCK EXCHANGE (NYSE)."**, para optar el Grado Académico de Doctor en Gestión de Empresas.

Luego de la exposición y absueltas las preguntas del Jurado Examinador se procedió a la calificación individual y secreta, habiendo sido **APROBADO** con la calificación de **DIECISIETE (17).**

El Jurado recomienda que la Facultad acuerde el otorgamiento del Grado Académico de Doctor en Gestión de Empresas, al **Mg. BAZÁN RAMÍREZ WILFREDO.**

En señal de conformidad, siendo las **11:20** horas se suscribe la presente acta en cuatro ejemplares, dándose por concluido el acto.

UNMSM Firmado digitalmente por INCHE MITMA Jorge Luis FAU 20148092282 soft
Motivo: Soy el autor del documento
Fecha: 20.02.2021 21:59:18 -05:00

Dr. INCHE MITMA JORGE LUIS
Presidente

UNMSM Firmado digitalmente por TINOCO GOMEZ Oscar Rafael FAU 20148092282 soft
Motivo: Soy el autor del documento
Fecha: 15.02.2021 10:44:10 -05:00

Dr. TINOCO GÓMEZ OSCAR RAFAEL
Miembro

UNMSM Firmado digitalmente por CEVALLOS AMPUERO Juan Manuel FAU 20148092282 soft
Motivo: Soy el autor del documento
Fecha: 16.02.2021 12:59:51 -05:00

Dr. CEVALLOS AMPUERO JUAN MANUEL
Miembro

Dr. ÁLVAREZ MERINO JOSÉ CARLOS
Miembro

UNMSM Firmado digitalmente por CHUNG PINZAS Alfonso Ramon FAU 20148092282 soft
Motivo: Soy el autor del documento
Fecha: 15.02.2021 10:20:08 -05:00

Dr. CHUNG PINZÁS ALFONSO RAMÓN
Asesor

DEDICATORIA

A mi esposa Nain Abigail a quien Jehová me dio como compañera en las buenas, en las enfermedades y en la muerte, en esta tierra del que somos residentes forasteros, pero con la segura esperanza de reencontrarnos cuando nuestro señor Jesucristo con su voz imperativa, nos levante de la sepultura y así, viviremos para siempre en esta tierra convertida en paraíso, lleno de abundancia, armonía, sabiduría y sin maldad.

A mi madre Teófila por su constante apoyo y encomio, a mi padre Angel y a mis hermanos.

AGRADECIMIENTO

Primero agradezco a Jehová Dios por su gran bondad inmerecida.

A la Universidad Nacional Mayor de San Marcos, a sus docentes de posgrado de la Facultad de Ingeniería Industrial, al profesor Eduardo Raffo Lecca y en especial al Doctor Alfonso Ramón Chung Pinzas, por su orientación y constante preocupación por colocarnos en el umbral del conocimiento.

A mi querida Universidad Nacional Federico Villarreal que me alumbró profesionalmente y me brindó enseñanzas a través de personas preclaras como: Juan Manuel Ontaneda Meyer, Oscar Benavides Cavero, Mario Valcárcel Aragón, José Bazán Briceño, Julio Figueroa Rodríguez, etc.

A mi empresa Telefónica por ser partícipe de ella y testigo de grandes acontecimientos, por su interés de mantener conectado a la sociedad y su contribución con el desarrollo del país.

INDICE GENERAL

LISTA DE CUADROS

LISTA DE FIGURAS

ANEXOS

RESUMEN

Los instrumentos financieros como el precio de las acciones poseen desenvolvimientos volátiles que ocasionan inquietudes en todo tipo de inversionistas. Por su estructura de datos, el precio de las acciones pertenece a las series de tiempo, porque toma valores en la línea del tiempo. Los inversionistas buscan rentabilidades cuando invierten en instrumentos financieros, razón por lo cual necesitan entender su comportamiento y pronosticarlos con el mínimo error posible, es en esta parte cuando se presentan dos enfoques predictivos diametralmente opuestos; una de estas posiciones, sostiene que el precio de las acciones tiene patrones repetitivos a lo largo del tiempo, y que la información del pasado es útil para realizar predicciones, concluyendo que estos patrones se repetirán en el futuro, sin embargo, sus detractores argumentan que esto no es posible, dado el comportamiento eficiente del mercado que captura toda la información, también el precio de las acciones, presenta caminatas aleatorias que dificulta o hace imposible su predicción a partir del pasado por su misma naturaleza de tener un comportamiento errático. La presente investigación, sostiene que si es posible pronosticar el precio de las acciones de Telefónica que se cotizan en New York Stock Exchange (NYSE) a partir de su pasado con la metodología Box y Jenkins o autorregresivo integrado de promedio móvil (ARIMA) y los modelos de la familia ARCH/GARCH. Estos modelos econométricos se caracterizan por su robustez al momento de modelar y pronosticar rentabilidades y volatilidades de series de tiempo univariados.

Palabras claves: Series de tiempo; estacionariedad; raíz unitaria; ruido blanco, varianza

ABSTRACT

Financial instruments like stock price are volatile that concern all types of investors. Due to its data structure, the stock price belongs to the time series, since it takes values on the timeline. The investor community seek financial profitability when investing in financial instruments, so they need to understand their behavior and forecast them with the minimum possible error. In this moment when two diametrically opposed predictive approaches are presented; one of these positions, argues that the price of stocks has repetitive patterns over time, and that the information from the past is useful for making predictions, concluding that these patterns will repeat in the future, but, its detractors argue that this is not possible, given that the market behavior is efficient and captures all the information, also the stock price presents random walks that make it impossible to predict it from its past due to its erratic behavior. This research argues that if it is possible to forecast the stock price of Telefónica shares that are traded on the New York Stock Exchange (NYSE) from its past with the Box and Jenkins methodology or the integrated autoregressive moving average (ARIMA) and the ARCH / GARCH family. These econometric models are characterized by their robustness when it comes to modeling and forecasting returns and volatilities of univariate time series.

Keywords: Time series; stationarity; unitary root; white noise; variance

CAPITULO 1. INTRODUCCION

1.1 Situación problemática

Telefónica (2010), sostiene que a pesar de que la industria de la Telecomunicaciones es el de mayor dinamismo y crecimiento y contribuye con el desarrollo económico de una región y que el Grupo Telefónica es líder a nivel mundial en la provisión de soluciones de conectividad e innovación, con presencia en Europa, África y Latinoamérica y que sus acciones son rentables; sin embargo, estas no son atractivas para los inversionistas.

Telefónica (2010), informa que durante el periodo 2007 al 2009, el precio de la acción de Telefónica subió un 21,9%. También de las observaciones realizadas en la página www.yahoo.es sobre el desenvolvimiento de las cotizaciones de las acciones de Telefónica S.A. (TEF.MC), se encontró que el 05 de agosto del 2013 la acción cerró en 10.84 Euros y el 05 de agosto del 2015 llegó hasta 14.21 Euros, en dos años subió 31.08%. Del 27 de junio al 08 de septiembre del 2016, la acción del Telefónica subió 27.26% en 73 días calendarios. Cabe resaltar que estas acciones se cotizan en la Bolsa de Madrid. Se puede concluir que se estaría perdiendo la oportunidad de obtener ganancias por no invertir en acciones de Telefónica sobre todo cuando existe volatilidad en sus diferentes periodos.

Alvarez-Pallete (2018) presidente de Telefónica, en carta dirigida a los accionistas, sostiene que Telefónica se está transformando debido a los cambios súbitos que se dan en el campo de la tecnología y en la sociedad que influyen directamente en los negocios y sobre todo al sector de las Telecomunicaciones. Agrega además de que Telefónica se encuentra en un

momento único, extraordinario y que posiblemente marcará la Historia. También indica que estos cambios generarán billones de euros de valor y que crearán miles de nuevos empleos, pero desaparecerán otros, también agrega que la primera necesidad del ser humano es la alimentación y después de esta, es la necesidad de comunicarse, por consiguiente, la nueva ola tecnológica ofrece la conectividad de datos.

Alvarez-Pallete (2018) resume el desafío que afrontará Telefónica será "doble: Por un lado, una radical transformación de la demanda, desde la voz hacia los datos y por el otro, la necesidad de construir una nueva infraestructura capaz de satisfacer esa nueva demanda que crece exponencialmente". Además, acota que esta situación en una oportunidad de "reinventar Telefónica e invertir en nuevas redes, adaptar la oferta y ser más sencillos y eficientes". Agrega que los "analistas empiezan a reconocer la visión de Telefónica y el consenso de los bancos de inversión sitúan el precio objetivo por acción en torno a los 10 euros".

Entonces, de acuerdo a las referencias vistas, se concluye que las personas y/o instituciones, tienen diversas alternativas de inversión, una de estas es el mercado de valores que opera tanto en Lima como en el extranjero. Sea cual fuere su tolerancia al riesgo, el inversionista siempre busca obtener ganancias. Al invertir en rentas variables como son las acciones, el inversionista no tiene suficientes conocimientos financieros, o puede actuar en base al rumor o experiencia compartida, por diversos medios informativos o páginas electrónicas, pero estas no lo ayudan a predecir el comportamiento del precio de las acciones. En ocasiones se dejan guiar por la tendencia o cuando el precio de las acciones que están al alza, pero al no obtener el rendimiento deseado prefirieren retirase perdiendo, presentándose un riesgo de mermar parte de su inversión o tener que esperar un largo tiempo para recuperar su inversión. Asimismo, con la aprobación de la libre disponibilidad del 95.5% de fondos de las AFP, los afiliados al Sistema Privado de Pensiones pueden retirar el fondo disponible en su Cuenta Individual de Capitalización (CIC), para realizar diversas inversiones. Una de estas alternativas de inversión es el mercado de valores y dentro de esta uno de los papeles más

atractivos son la compra y/o venta de acciones de Telefónica S.A. y así obtener retornos sobre sus inversiones; por ello es necesario contar con modelos explicativos para predecir el comportamiento de las inversiones en acciones de Telefónica y medir la volatilidad del precio de sus acciones y de esa manera obtener retornos en dichos activos financieros intangibles. Por eso, con esta investigación se pretende utilizar la metodología Box y Jenkins, los modelos GARCH para pronosticar los precios, su rentabilidad y volatilidad de las acciones de la Compañía Telefónica de España, que se negocian en la Bolsa de Valores de Lima u otras plazas como la Bolsa de Madrid, Nueva York, entre otras.

1.2 Formulación del problema

Problema Principal

¿Cómo aplicar modelos condicionados a su pasado para pronosticar adecuadamente los precios de las acciones de Telefónica cotizadas en la New York Stock Exchange (NYSE)?

Problemas secundarios

- ¿Cómo la diferenciación de los precios de cierre influirá en la media de los retornos de las acciones de Telefónica?
- ¿Cómo el nivel de volatilidad identificará la varianza de los retornos de las acciones de Telefónica?
- ¿Cómo los niveles de noticias identificarán la asimetría de la volatilidad de los retornos de las acciones de Telefónica?
- ¿Cómo los valores extremos de los retornos identificarán la curtosis de la volatilidad de las acciones de Telefónica?

1.3 Justificación

Telefónica (2010), asegura que esta compañía tiene más de 85 años y es una de las más importantes compañías en el mundo de las telecomunicaciones. En los últimos años, ha cumplido todos objetivos de rentabilidad fijados por la propia compañía, así como el crecimiento de los beneficios y el beneficio neto. Sus sólidos resultados financieros en el

mercado desde que comenzó a cotizar en bolsa en el año 1925, los respaldan ampliamente. También es una de las compañías de referencia en la industria de las telecomunicaciones – 4ª en la lista Top 5 del sector y 1ª operadora en índices bursátiles que valoran la sostenibilidad- que se refleja en sus datos históricos al 2010, Telefónica era la 1ª operadora internacional integrada de telecomunicaciones del mundo por número de clientes; la 1ª operadora integrada por capitalización bursátil a nivel europeo, y ocupaba la primera posición como operadora en el índice Dow Jones Sustainability, encontrándose situada entre las 50 empresas más grandes del mundo por capitalización bursátil, y en el grupo de las 100 empresas con más ingresos del mundo. Telefónica es líder indiscutible en el mercado de las Telecomunicaciones en América Latina, y evidencia un perfil de diversificación geográfico único de entre las grandes operadoras mundiales en relación a sus ingresos, OIBDA, accesos por regiones y accesos por negocios. A pesar de las crisis de los mercados financieros, Telefónica ha podido comportarse notablemente comparado con otras empresas de la misma industria.

Alvarez-Pallete (2018) indica que la industria de la comunicación después de la alimentación es la principal necesidad. La conexión de datos y su volumen crecen a un ritmo de entre el 50 y el 60% anual, finaliza sosteniendo en las grandes inversiones realizadas por Telefónica de que es fuerte y que avanza decidida hacia su futuro y que tendrás reflejo en la acción.

EFE (2018) en el sitio web de yahoo Finanzas, Gonzalo Gortázar consejero delegado de Caixabank, justifica su permanencia del 5% como accionistas en Telefónica, al considerarlo un buen socio de negocio tecnológico, a la vez agrega que "Es una magnífica inversión, muy infravalorada actualmente en Bolsa, entre otras cosas por el ruido que existe sobre algunas economías emergentes donde opera y que la gestión y el liderazgo del presidente de Telefónica, José María Álvarez-Pallete son extraordinarios". Esto en concordancia con lo expresado por Alvarez-Pallete (2018), en el sentido de que Telefónica es una empresa tecnológica y que sus acciones tienen fundamentos para tener altas cotizaciones en los mercados bursátiles.

Por lo tanto, se puede concluir que los instrumentos financieros de Telefónica son atracciones para los inversionistas por su gran fortaleza y por esta razón, es conveniente realizar esta investigación para pronosticar el rendimiento y la volatilidad de las acciones de Telefónica, S.A. que se cotizan en la bolsa de New York Stock Exchange (NYSE), debido a que su movimiento bursátil es mayor comparado con la Bolsa de Valores de Lima.

El autor de esta tesis pretende contribuir con modelos econométricos un mejor entendimiento del comportamiento de variabilidad del precio de cierre y retorno de las acciones de dicha compañía, por dicha razón primariamente esta investigación está dirigida a los trabajadores Telefónicos pues cada cierto tiempo, son invitados a invertir en un Plan Global de compra de acciones. También a las personas que se están retirando por jubilación y disponen del 95.5% de sus aportes en las AFP. Y en forma general, está dirigido a otros inversionistas interesados en papeles de Telefónica, asimismo se busca brindar métodos estadísticos para un pronóstico confiable, para una inversión segura, que ayude a manejar las volatilidades, asimismo, se propondrá una solución computacional económicamente accesible que permita simular y pronosticar activos financieros.

1.4 Objetivos de la investigación

1.4.1 Objetivo general

Determinar cómo aplicar modelos condicionados a su pasado para pronosticar adecuadamente los precios de las acciones de Telefónica cotizadas en la New York Stock Exchange (NYSE).

1.4.2 Objetivos Específicos

1. Determinar cómo influye la diferenciación de los precios de cierre en la media de los retornos de las acciones de Telefónica S.A.
2. Determinar cómo influyen el nivel de volatilidad en la varianza de los retornos de las acciones de Telefónica S.A.
3. Determinar cómo influyen los niveles de noticia en la asimetría de la volatilidad de los retornos de las acciones de Telefónica S.A.
4. Determinar cómo influyen los valores extremos de los retornos de las acciones en la curtosis de la volatilidad de los retornos de las acciones de Telefónica S.A.

CAPITULO 2. MARCO TEÓRICO

2.1 Marco Filosófico e Epistemológico de la Investigación

La Real Academia Española (RAE, 2017) define a la ciencia como un "Conjunto de conocimientos obtenidos mediante la observación y el razonamiento, sistemáticamente estructurados y de los que se deducen principios y leyes generales con capacidad predictiva y comprobables experimentalmente", entonces se puede definir el conocimiento científico como parte de la ciencia y que Chung (2016) a su vez sostiene que esta ha sido estudiada por el método científico.

En efecto, desde los albores de la humanidad, el problema central fue acertar en los pronósticos pues un resultado muy alejado de la estimación, impactará negativamente en los objetivos de una organización empresarial o de un inversionista particular, entonces surgen preguntas para encontrar respuestas que ayudan a tomar una adecuada decisión utilizando el método científico para construir teorías que tratan de entender y acercarnos a la realidad por medio de la investigación científica, se recurren a antecedentes bibliográficos para fortalecer una investigación por medio del método inductivo y se transitará de lo particular a lo general, buscando conexiones entre estos antecedentes lo que nos llevará a construir una teoría general o dicho de otro modo la creación de leyes teóricas a partir de hechos particulares observados y que puede ser probado estadísticamente. Pero si se quiere comprobar una proposición como en la presente investigación que busca pronosticar el desenvolvimiento de activos financieros, se recurre al método deductivo para ir de lo complejo a lo simple o inferir una observación partiendo de una ley general o teoría y descendiendo para formular una hipótesis preliminar,

definiendo premisas, la observación y finalmente la confirmación. Se debe recalcar que la parte más importante de este método es la hipótesis.

Salcedo (2012) sostiene que cuando se habla sobre la ciencia, la epistemología “se ocupa de la normativización de la ciencia, del método científico y de la crítica a teorías científicas” y supone a la epistemología como una rama de la filosofía, un filosofar que tiene como temática a la ciencia, a la que considera muy importante como una sub rama de la teoría del conocimiento, pero también diferenciada. Agrega además que la teoría del conocimiento estudiará todas las formas posibles de conocimiento y que la Epistemología se concentrará en la parte científica.

Considera además a la actividad epistemológica un filosofar sobre la ciencia, no solo analiza los supuestos filosóficos de la investigación científica sino va más allá colocándose en un nivel superior al científico: el metacientífico. Y que a partir de cualquier historia de la filosofía y del pensamiento científico puede distinguirse dos formas clásicas de concebir la ciencia: la aristotélica y galileana.

Ciencia aristotélica: Para Aristóteles la fuente de la ciencia es la observación y que lo importante era dar cuenta de lo observado y que por tanto la explicación científica se logra cuando se dan razones sobre lo observado y que concebía el saber científico reconociendo la inducción: la observación de hechos particulares hasta arribar a los principios generales o explicativos, pero lo importante cuando de allí se deducían enunciados acerca de los hechos a partir de las premisas que debían contener los principios explicativos y que en ese sentido, la causa de un fenómeno tiene cuatro aspectos; formal, material, eficiente y final o telos pero que Aristóteles pone especial énfasis en el último aspecto,

Ciencia galileana: Tomando en cuenta de que las ideas de Aristóteles partían de los principios evidentemente ciertos, axiomas y luego se construían las teorías mediante la deducción. Galileo supone que antes de ello debe estar la inducción; antes de formular una teoría se requieren de experimentos que se deben repetir una y otra vez. De ello, deben salir exactas mediciones que den

cuenta de la objetividad de la labor. Fue tarea de Galileo y sus seguidores reducir a fórmulas matemáticas las propiedades de los fenómenos.

Ñaupas, Mejía, Novoa y Villagomez (2014) afirma que los significados de la epistemología varían de acuerdo a las escuelas filosóficas, pero es "a partir de la década de los 30 del siglo pasado, que surgió con fuerza esta nueva rama de la filosofía que amenazó con enterrar a la Gnoseología o Teoría del Conocimiento", pero se consolida después de 1927. Citando a Bunge, Ñaupas et al (2014) dice que es la rama de la filosofía que estudia la investigación científica y su producto, el conocimiento científico.

Ynoub (2015) sostiene la importancia de las hipótesis en la investigación, luego surgen preguntas sobre "que es y no es ciencia", que enriquecen el debate en el escenario epistemológico y las diversas formas de abordar el quehacer científico posiciones sobre y que revisa cada una de las posiciones pero "a la luz de una de las posiciones epistemológicas que ha tenido mayor impacto en el contexto científico contemporáneo desarrollado por Karl Popper bajo la fórmula del método hipotético-deductivo". Argumenta que Popper tiene una peculiar posición en los debates epistemológicos y que "la posición popperiana estriba en sostener que los enunciados científicos son inverificables y no se puede demostrar de manera concluyente la verdad de los enunciados universales mediante la razón ni mediante la experiencia". Coincide con los empíricos en cuanto al manejo del desarrollo científico, pero discrepa sobre el origen del conocimiento, rebate la posición de que la inducción no demuestra categóricamente el conocimiento, Agrega que "las hipótesis pueden ser falsadas pero no verificadas, en caso las hipótesis resistan las contrastaciones se les considerará corroboradas pero nunca probadas". Se aporta del debate entre teoría y práctica y "se reconoce que la aceptación o el rechazo de la experiencia, al igual que los enunciados espaciotemporales singulares que se utilizan para contrastar las hipótesis, son fruto de un acuerdo convencional (metodológico)".

Con referencia al falsacionismo sofisticado de Imre Lakatos, Ynoub (2015) sostiene que el método hipotético-deductivo popperiano y su concepción falsacionista, no estuvo a la altura del desarrollo científico y

agrega que se interesó del falsacionismo, luego de los ataques a la epistemología popperiana para rescatar y desarrollar una nueva propuesta. Examinando el comportamiento científico que exige el método hipotético-deductivo encontró evidencias empíricas para rebatir “varios de los supuestos de la concepción falsacionistas y que fue Imre Lakatos quien sistematizó y señaló los límites que presentaba la versión original del falsacionismo dogmático y su posterior desarrollo, al que llamó falsacionismo metodológico ingenuo. Además Lakatos evalúa una cadena de teorías relacionadas y forman un conjunto de programa de investigación científica que tiene un núcleo duro o firme que tiene teorías aceptadas e incuestionables que no se someten a prueba; una barrera o cinturón protector de hipótesis que contrastan los hechos protegiendo al núcleo y dos heurísticas que dirigen la investigación, la heurística positiva que estás en la barrera de protección indica desarrollar o modificar estas barreras y la heurística negativa guías las caminos para no refutar el núcleo.

En cuanto a la discusión epistemológica de la relación sujeto-objeto desde el momento que nace la filosofía, el autor afirma que quizás la discusión epistemológica más intensa ha sido la de la relación sujeto-objeto y que se postulan las preguntas ¿puede llegar a conocerse? y ¿Qué es el conocimiento? Si la respuesta fuera negativa la posición del investigador será el escepticismo. Sin embargo, si la respuesta fuera afirmativa se presentan dos “posiciones de respuestas que dependen de la respuesta a la pregunta ¿Cómo podemos conocer?”. Si el conocimiento se adquiere por medio del sujeto, entonces estamos frente a corrientes subjetivistas o idealistas, pero si se adquiere conocimiento por medio del objeto, entonces estaremos ante corrientes objetivistas o empiristas y que “en síntesis el problema del conocimiento ha girado en torno al énfasis que se haga o bien al sujeto o al objeto”.

Salcedo (2012) con respecto al positivismo dentro de las ciencias sociales sostiene que el siglo XIX es el siglo del despertar de las ciencias del hombre, estas incipientes pero ambiciosas ciencias del hombre partieron de la idea de que para mantener el status de ciencia y obtener buenos resultados prácticos y teóricos como las ciencias naturales, debían proceder bajo la

filosofía y metodología de las ciencias naturales y es a partir de allí que se desarrollará una de las posiciones orientadoras del pensamiento científico social: el positivismo. Este positivismo científico-social se propone hacer ciencia siguiendo la tipificación ideal de la física matemática, matizando tan solo un poco la importancia de las leyes generales, pero conservando la metodología. Sin embargo, las críticas al modelo positivista no se hicieron esperar sobre todo en el ámbito de la filosofía alemana haciendo hincapié en que la función social no es explicar sino comprender los fenómenos.

Existe un carácter sumamente variable de la idea de la ciencia que permite afirmar que la ciencia es una actividad históricamente mudable, pero se pueden llamar respuestas históricas a aquellas que intentar dar respuesta sobre esta variabilidad de la ciencia, pero en eses sentido dos han sido las principales respuestas de este tipo: el esencialismo y el nominalismo. El esencialismo supone que tal variabilidad se debe a la misma dinámica interna de la ciencia, que es muy compleja. La ciencia existe, aunque no se haya podido comprender aún su esencia, por lo que es tarea primordial del filósofo y el científico ir tras esa esencia. Por otra parte, el nominalismo supone la inutilidad de ir tras esa esencia y que tal variabilidad es propia de la ciencia. La característica fundamental de la actividad científica es su “revisibilidad”, su negociación, su reclasificación. Por ello se dice que “la ciencia” y el “método científico” no existen. Todo lo llamado ciencia es, por lo tanto, el trabajo de científicos y filósofos, de ellos y solo de ellos surgen las características de la ciencia. Por tanto, no existe algo afuera llamado ciencia a la espera de que se halle su esencia; y lo que se llama ciencia depende así del propósito específico de sus trabajadores.

Citando a Peñaloza que sigue a Platón (Ñaupas et al, 2014) “distingue dos tipos de experiencia del conocer: episteme, es decir, conocimiento auténtico, conocimiento científico; y, doxa, es decir, opinión, creencia, noción”. La opinión o doxa de los griegos, por oposición al conocimiento científico, la episteme, es una experiencia del conocer que se caracteriza por ser subjetiva, individual, no comprobable, variable, y sin fundamento y es la experiencia que adquieren las personas iletradas y del vulgo que orgullosamente denominan

“la escuela de la vida”, pero que carecen de rigurosidad y sustento cuando pretender ser explicarlas.

Bunge (2012) sostiene que los filósofos son teóricos pero temerosos del trabajo manual y agrega, que es indigno para los pensadores que se sentían de clase superior, prestar interés alguno a la tecnología, por el contrario, fueron los positivistas y pragmáticos quienes, si mostraron interés por la técnica debido a su impacto social a pesar de la confusión de la técnica con la ciencia, “La tecnología, en suma, no ha constituido para ellos tema de reflexión filosófica”.

> Pero esa actitud despectiva, temerosa e ignorante para con la tecnología comenzó a cambiar después de la Segunda Guerra Mundial, al menos en los países cultos. En EE.UU. y, en menor medida, en otros países que marchan a la cabeza de la cultura, se está comprendiendo que la tecnología no sólo exige el concurso de científicos sino también la colaboración de filósofos. En ese país se están multiplicando las empresas y los institutos de investigación tecnológica que emplean lógicos y epistemólogos, no por considerarlos adornos sino porque son indispensables para abordar problemas generales que requieren la comprensión de estructuras lógicas y de analogías entre sistemas y disciplinas diversas, problemas que el especialista no está habituado a abordar (Bunge, 2012, pp.48-49).

Agrega además Bunge (2012), que “todavía no se ha constituido una filosofía de la tecnología a semejanza de la epistemología”. Cuando se refiere a las tecnologías contemporáneas, las subdivide en “tecnología física (las ingenierías); b) tecnología biológica (medicina, farmacología, odontología, etc.), y c) tecnología social (derecho, pedagogía, investigación operativa, ingeniería social, etc.)”, pero el desarrollo de la ciencia, puede también ser impulsado por la tecnología pues es inherente a esta, empero “si la ciencia pura engendra tecnologías, éstas a su vez plantean problemas científicos que promueven el adelanto de la ciencia”. También sostiene que “quien diseña el experimento es un científico, pero es cada vez más frecuente que el científico sea asistido por ingenieros que se ocupen de diseñar, no el experimento, pero sí parte del equipo experimental”, y que tecnologías físicas contribuyen a las

ciencias experimentales permanentemente debido al cambio continuo del entorno, de la información concatenada y con ayuda del método y la teoría científica, “En el curso de los últimos decenios hemos asistido a la conversión de diversas técnicas en tecnologías que moviliza a centenares de miles de lógicos, matemáticos, físicos, químicos, biólogos, psicólogos y sociólogos”. Los técnicos y tecnólogos son más de acción, mientras que los científicos y filósofos buscar conocer o saber más.

> No hay duda de la estrecha unión de la ciencia pura con la ciencia aplicada en el mundo actual, y tampoco se duda acerca de que la ciencia pura emplea como medio lo que es fin para la ciencia aplicada y viceversa. Esta estrecha unión entre el saber teórico y el saber práctico no existió antes de la Edad Moderna y ha sido consagrada por la teoría pragmatista de la unidad de la teoría con la práctica, de la identidad del saber y del hacer y, en particular, del saber y del saber hacer (…). La diferencia entre saber y saber hacer permite explicar la coexistencia del saber práctico con la ignorancia teórica, y del saber teórico con la ignorancia práctica (Bunge, 2012, pp.56-57).

Otra tesis del pragmatismo es que la verdad consiste en la eficacia. Bunge (2012) afirma que un análisis metodológico muestra que existe una relación fuerte entre la ciencia y la tecnología contemporánea, pero estas difieren pues la ciencia busca la verdad mientras que la tecnología se centra en la eficacia. “La investigación tecnológica, llevada a cabo con el método de la ciencia, es la única capaz de poner a prueba la verosimilitud de las hipótesis y la eficacia de las reglas”.

> En suma, el éxito no es condición necesaria ni suficiente para dar por satisfactoriamente corroborada una hipótesis o un sistema de hipótesis (teoría). En otras palabras, es falso que la práctica sea la piedra de toque de las teorías, y este falso criterio de verdad es en parte responsable de la supervivencia de numerosas supercherías en las técnicas físicas, biológicas y políticas (Bunge, 2012, p.62).

Bunge (2012) cuando se refiere a la Ley y regla hace la distinción resumiendo los desacuerdos entre ciencia y técnica. Dice que “una regla es una norma de acción humana. Una ley, en cambio, enuncia lo que algo es”,

agreda que las leyes pueden ser verdaderas, pero no eficaces mientras que las reglas pueden ser eficaces, pero no ciertas. “Con referencia a la investigación científica, investigación tecnológica e innovación hace la diferencia entre las actividades de los científicos, tecnólogos y técnicos”. Cuando se refiere a los científicos sostiene que estos:

> tratan casos puros con procedimientos rigurosos con el fin de maximizar la verdad; los tecnólogos tratan casos semipuros con procedimientos semirrigurosos con el fin de encontrar verdades aproximadas que permitan fundamentar reglas eficaces; y los técnicos tratan casos impuros con procedimientos no rigurosos con el fin de maximizar el rendimiento. Lo que llama caso puro es el fenómeno simplificado idealmente, el modelo esquemático que no corresponde exactamente a la realidad, que tiene en cuenta unos pocos aspectos de los sistemas reales y que es producto de la inventiva científica. Entre el técnico que trata con situaciones reales, no simplificadas, y que las trata prácticamente, por una parte, y el científico que trata con modelos conceptuales a menudo alejados de la realidad, se ubica el tecnólogo que estudia casos intermedios entre los reales y los puros. La tarea del tecnólogo experimental consiste, pues, en poner a prueba modelos tecnológicos teóricos con ayuda de modelos materiales (Bunge, 2012, p.67).

Cuando el científico selecciona un problema, sea por su relación con la teoría científica, se da cuenta del contraste entre la investigación científica y la tecnológica dado que nota el impacto y el interés que esta tiene, pero el tecnólogo, solo desea la solución de las problemáticas. Pero la actualidad no es la supremacía de la técnica como algunos creen, pues esta se desarrolló antes de la ciencia, sino, es el predominio de esta última. “Recién ahora se puede pensar en el dominio de la cosa por la idea, en la primacía del espíritu”. Empero en estos tiempos surge con ahínco la llamada filosofía de la tecnología y que debe ser tomada en cuenta por los filósofos a fin de entender el futuro.

Bunge (2009) sostiene que habría que filosofar científicamente y agrega que hay tres opiniones sobre la ubicación de la filosofía con respecto

de la ciencia, pero critica la idea de que la filosofía y la ciencia estén separadas pues tienen muchos temas en común y rebate las ideas positivistas de que la ciencia desplazará al a filosofía y da algunos ejemplos de problemas filosóficos que intentar convertirse científicamente sin llegar a serlos.

Problema 1: sentido y referencia. La contribución de Bunge (2009) empieza por corregir el análisis fregeano del concepto de predicado. Lo define como una función que aplica (mapea) el conjunto de referentes sobre el conjunto de las proposiciones que contienen el predicado en cuestión.

Problema 2: verdad fáctica o adecuación a los hechos. Todos los científicos usan tácitamente la llamada teoría de la correspondencia o adecuación de las ideas a los hechos.

Problema 3: explicación científica. La dilucidación estándar del concepto de explicación científica la identifica con la inclusión de un particular en un universal. En las ciencias y técnicas se dice que un hecho se explica si se descubre o adivina el mecanismo que la produjo.

Problema 4; concepto general de energía. Cada capítulo de la física define su propio concepto de energía: cinética, elástica, térmica, electromagnética, etc. y más aún cada capítulo de la física formula su propio principio de conservación de la energía. El problema puede resolverse examinando los diversos conceptos especiales de energía se advierte que todos ellos están ligados al cambio, ya actual, ya potencial.

Problema 5: espacio. Desde la antigüedad clásica el problema de qué (no solo cómo) sea el espacio ha interesado tanto a matemáticos y físicos como a filósofos. Así se tiene numerosas teorías topológicas y geométricas de espacios matemáticos, y casi todas las teorías físicas contienen alguna teoría geométrica (adecuadamente interpretada en términos físicos). La geometría filosófica del autor cumple el programa de Leibniz, de construir una teoría relacional del espacio y del tiempo, ya que los concibe como la estructura básica y objetiva de la colección de las cosas cambiantes.

Problema 6: Vida. Hay dos concepciones rivales de la vida: la vitalista y la materialista. La primera fue destruida por Claude Bernard y otros hace más de un siglo. Pero el materialismo se ha dividido en tres ramas: el fisicoquimismo o reduccionismo, el maquinismo y el organicismo. El fisicoquimismo sostiene que los seres vivos son sistemas fisicoquímicos muy complejos. Esta concepción vale solo para los componentes subcelulares de los organismos, así como para algunos aspectos de los procesos "organísmicos". Tanto el fisicoquimismo como el maquinismo pasan por alto la emergencia o aparición de cosas y procesos cualitativamente nuevos, tales como la célula, el metabolismo y la especiación. El organicismo hace hincapié en la emergencia. Sostiene que los organismos son sistemas naturales (no diseñados) cuyos componentes son fisicoquímicos pero que, al nivel de sistemas (células, órganos, etc.) poseen propiedades emergentes.

Problema 7: mente-cuerpo. Este también es un problema milenario, y más aún interdisciplinario, ya que interesa tanto a filósofos como a neurocientíficos, psicólogos y expertos en inteligencia artificial.

Problema 8: El filósofo no puede estar al margen de las computadoras y debe tomar posición debido a que la sociedad recurre a estas para facilitar sus actividades cotidianas.

Problema 9: individualismo-holismo. La alternativa entre el individualismo y el holismo se presenta en todos los campos del saber, desde las matemáticas hasta la sociología.

Problema 10: verdad moral. La mayoría de los filósofos modernos han relativizado los juicios de valor y en particular, los morales de acuerdo a su conveniencia deviniendo en amorales (Bunge, 2009, pp.124-132).

2.2 Antecedentes de investigación

Mun (2016), sostiene que cuando no existe información histórica se recurre a juicio de expertos para ayudar a anticiparse a los acontecimientos que puedan afectar tanto positivamente o negativamente las inversiones, pero cuando existe información histórica se puede valer de sus mismos datos y con

la ayuda de la estadística pronosticar y que dicho pronóstico tenga el mínimo error, esta información histórica es una línea temporal o secuencia de puntos equidistantes deviniendo todo este proceso en el llamado series temporales o serie de tiempos porque sus observaciones están en función del tiempo, pero el tema principal radica en que estos puntos u observaciones tienen volatilidad, entonces cuando estas instituciones o los inversionistas, pronostican series temporales o comportamiento de variables, estas tienen cuatro componentes o patrones que pueden tener tendencia que sube o baja a largo plazo esta tendencia, también puede tener un ciclo que es un componente en forma de onda alrededor de la tendencia formando dos componentes a largo plazo, un tercero que es el componente estacional que se repite anualmente en los mismos trimestres, meses semanas, etc. siendo un componente previsible y finalmente un componente irregular que es como un componente residual de la series de tiempo que no se puede explicar ni por tendencia, ni por ciclo, ni por estacionalidad como algo remanente o patrón outliers de la serie. Asimismo, en pronósticos de series temporales se presenta la no estacionariedad término diferente a la estacionalidad, pero en sentido débil debido a que sus primeros momentos tanto la media como la varianza, no varían en el tiempo, vale decir que no dependen del tiempo ósea, que la medias y varianza son constantes, en cambio las no estacionariedad en sentido fuerte, todos los momentos son invariantes al tiempo. Se puede decir que desde tiempos inmemorables se ha buscado conocer el futuro, en el ámbito inversor tanto las instituciones como los individuos pretenden estimar lo que sucederé en el mañana.

Entonces, Bello (2017), afirma que, al pronosticar una serie de tiempo, se debe tomar en cuenta los cuatro patrones o componentes y dependiendo de los componentes que tenga la serie temporal se podrá utilizar una técnica de pronóstico en particular y para comprobar si se ajustó adecuadamente o no, se utilizará tres estadísticos de error como el MAPE (Error Porcentual Absoluto Medio), RMSE (Error Cuadrático Medio) y el coeficiente de desigualdad de Theil (U-Theil) que juzgan el pronóstico. Estos ajustes permitirán seleccionar la técnica de pronóstico que tenga el estadístico de error lo más pequeño posible

Asimismo, en pronósticos de series temporales se presenta la no estacionariedad término diferente a la estacionalidad, pero en sentido débil pues solo los primeros momentos como la media y la varianza, son invariantes en el tiempo, vale decir que no dependen del tiempo ósea, que la medias y varianza son constantes, en cambio las no estacionariedad en sentido fuerte, todos los momentos son invariantes al tiempo.

Se ha podido encontrar investigaciones que se valen de dichos instrumentos como los métodos cuantitativos como las series temporales para pronosticar eventos; en la investigación realizada por Herrera (2013) sobre series temporales, utilizó el "modelo estocástico a partir del Razonamiento Basado en Casos" y aplicó "en la generación de escenarios climáticos en el ámbito de la cuenca del Chili-Arequipa". Sostiene que el problema de los modelos tradicionales al hacer uso de aproximaciones lineales deviene en modelos no eficientes y poco aplicables, agrega además que "los modelos no-lineales, necesitan un conocimiento profundo del dominio para su construcción y para ello propone un modelo de Proceso Estocástico para la generación de series temporales con la capacidad de capturar detalles ocultos, con las siguientes características":

- Modelo genérico que puede ser implementado en una amplia gama de fenómenos no lineales de comportamiento estocástico.
- Modelo con la capacidad de manejar todos los casos incorporados a la memoria.
- Modelo auto-regresivo, en series temporales que presenten un fenómeno de persistencia observable.

El investigador toma una muestra de 2,700 series temporales, 32,400 datos un periodo de 29 años desde 1970 a 1999 y los procedimientos que utilizó fueron "los modelos de comparación utilizados son el Modelo de Thomas Fiering y el Modelo Estocástico Neuronal de Luciana. Los parámetros utilizados para evaluar a nivel mensual son la media, desviación estándar, el coeficiente de asimetría, máximos y mínimos", se obtuvieron resultados que muestran la propuesta de realizaciones que reproducen las características de la serie; "luego el uso de casos multidimensionales y de grados superiores genera series leptocúrticas, lo que en ciertos casos no reproduce las

características de los datos, pero reduce la incertidumbre".

Por otra parte Oliver (2013) para la modelación de la volatilidad condicional en índices bursátiles, compara el modelo Egarch con la red neuronal backpropagation, fundamenta que la volatilidad es una medida de riesgo pero no señala el desenlace diario de las cotizaciones y sostiene la necesidad de "una medida estadística que calcule la máxima pérdida posible que puede sufrir una cartera determinada durante un periodo de tiempo concreto" y al contrastar un modelo econométrico de la familia Garch y una red neuronal de tipo backpropagation para pronosticar la varianza condicional sobre varios índices bursátiles internacionales. La hipótesis planteada es que las redes neuronales artificiales pueden descubrir relaciones más complejas entre las variables y, por tanto, predicen con mayor certeza la volatilidad que los modelos clásicos econométricos, para ello tomo como muestra 5 índices de diversos tamaños y estructura y de diferentes mercados bursátiles. El DAX alemán, IBEX-35, NIKKEI-225, NASDAQ-100 y S&P-500. El periodo muestral escogido parte desde inicios del 2000 hasta finales del 2010. Los procedimientos utilizados por el autor fueron "el modelo de Thomas Fiering y el modelo Estocástico Neuronal de Luciana. los parámetros utilizados para evaluar a nivel mensual fueron la media, desviación estándar, el coeficiente de asimetría, máximos y mínimos". Los resultados "muestran que la propuesta genera razonablemente realizaciones que reproducen las características de la serie, particularmente para el caso de valores mínimos extremos, representando una mejora" y se presentan series leptocúrticas en la utilización de casos multidimensionales y de grados superiores. En algunas ocasiones no muestra la característica de los datos, pero la incertidumbre se diluye.

Otra investigación realizada por García (2014) sostiene que es frecuente observar en los rendimientos pasados de los instrumentos financieros, una relación compleja entre estas pues presentan una leve asimetría y alta curtosis, a raíz de esto, propone utilizar modelos más flexibles para tomar en cuenta estas características "un proceso estocástico que sea capaz de manifestar la relación intertemporal entre las observaciones, así como una distribución que pueda capturar la asimetría y las colas pesadas de

manera simultánea” en tal sentido su primera propuesta es utilizar un proceso GARCH, para modelar series temporales univariados; su segunda propuesta es un modelo de Correlación Condicional Dinámica, enarbolado por Tse y Tsui, para series temporales multivariados, para el caso univariante, la muestra considera Log-rendimientos del índice de Standard & Poor's del 3 de enero de 2000 al el 28 de diciembre de 2013, En el caso series univariante utilizó la distribución normal o Gaussiano por que conduce a una mejor comprensión de la distribución Skew-Slash. Sus resultados ilustraron el poder de los modelos y metodologías propuestos, volvió a varios conjuntos de datos. En primer lugar, trabajó con varios datos simulados Conjuntos de diferentes tamaños para ilustrar la capacidad de la Máxima Verosimilitud y luego eligió uno de los conjuntos de datos simulados para evaluar la metodología bayesiana y comparar ambas propuestas. En segundo lugar, estudió una serie de log-retornos que fueron extraídos del índice de Standard & Poor's entre 3 de enero del 2000 y 28 de diciembre del 2013 utilizando ambos métodos, y comparándolos.

Villalba y Flores (2014) al analizar el comportamiento de la volatilidad del índice de precios y cotizaciones (IPC) del 2002 al 2013 del mercado bursátil mexicano para estimar la tendencia de los precios de las acciones que la componen, verificaron la importancia de la estacionariedad de dichas series que fueron trasformadas cuando aplicaron una diferencia logarítmica para convertirlos en rendimientos continuos y estacionarios. Al Presentar la aplicación del “modelo GARCH trivariado asimétrico para pronosticar la causalidad entre las series del principal índice bursátil mexicano, del índice de riesgo país para México y de la mezcla mexicana de exportación”, encontraron que se presenta relación entre las series y que son significativas cuando se hacen pronósticos.

En la tesis doctoral de Chung (2014) se halló que sostiene que los modelos ARCH/GARCH y sus variantes han ganado mucha atención y siguen siendo la opción popular para modelar la volatilidad en estos días. Pero muy a pesar de su popularidad, sufren desde la flexibilidad del modelo. La volatilidad es una variable latente y, por lo tanto, poner una estructura de modelo específica viola esta suposición de latencia planteándose el autor

como objetivo proponer una clase de modelos de volatilidad multiplicativa semiparamétrica. Define la volatilidad como un producto de partes paramétricas y no paramétricas. Debido a la restricción de positividad, toma las transformaciones logarítmicas y cuadradas sobre la volatilidad. Supone que la parte paramétrica es GARCH (1,1) y sirve como una conjetura inicial a la volatilidad. Estimó GARCH (1,1) utilizando el método de verosimilitud condicional. La parte no paramétrica asume una estructura aditiva. La muestra tomada son datos de tipo de cambio. El modelo propuesto utilizó seis tipos de cambio diarios. Consideró el intercambio diario las tasas de seis principales monedas frente al dólar estadounidense. Estas monedas son Euro (EUR), yen japonés (JPY), la libra esterlina (GBP), el dólar australiano (AUD), el franco suizo (CHF) y el dólar canadiense (CAD). Los tipos de cambio comienzan a partir del 4 de enero de 1971 y terminan el 14 de junio de 2013. Desde que el euro se introdujo el 1 de enero de 1999 en el mercado financiero, comienza el conjunto de datos EUR / USD A partir del 4 de enero de 1999. Todos los conjuntos de datos se obtuvieron del sitio web http://research.stlouisfed.org/fred2/categories/158. Utilizó 3376 log-returns diarios (en porcentajes) del índice S & P 500 de Standard & Poor's de los Estados Unidos entre enero de 1990 y octubre de 2003. El conjunto de datos es utilizado por Audrino y Bühlmann y pudo obtenerse de Http://www.blackwellpublishing.com/rss. Investigó el modelo propuesto a través de simulaciones. Comparó el modelo con los modelos de volatilidad paramétrica existentes utilizando tanto medidas de rendimiento en la muestra como fuera de la muestra. No consideró la estimación de la función media, pero la serie fue ajustada en promedio. La distribución G se limita a tener el centro 0 y la varianza H. En las simulaciones, lo restringió a ser normal y la distribución t con 3 grados de libertad. Considerando cuatro diferentes modelos de volatilidad.

Los resultados del modelo propuesto, fue comparado con los modelos populares de volatilidad paramétrica: GARCH (1,1), EGARCH (1,1) y GJR-GARCH (1,1). El modelo mostró mejoras significativas sobre los modelos de volatilidad competitivos durante las simulaciones, En varios casos, se observó que EGARCH (1,1) no funcionó bien o no estimó el modelo, especialmente

cuando la distribución subyacente fue de cola pesada. Esto pudo deberse a la distribución normal de innovación normal. Los seis principales tipos de cambio y el S & P 500 se consideraron conjuntos de datos reales. Considerando cuatro diferentes medidas de bondad de ajuste para examinar los potenciales predictivos ya que la verdadera volatilidad nunca se conoce en la práctica. Bajo las medidas de bondad de ajuste RMSE, MADE, y LL, el modelo propuesto claramente superó a los otros modelos durante el período de la muestra. El modelo mostró una mejora en cuatro conjuntos de datos de tipos de cambio y S & P 500.

Hossain, Kamruzzaman y Ali (2015), exploran un modelo estadístico adecuado tanto para los inversores como para los investigadores para resolver la estimación futura del volumen de acciones utilizando datos de volúmenes de existencias diarios de Dhaka Stock Exchange (DSE). Con el volumen de existencias miden la variación en los precios de las acciones que generalmente están asociados con los cambios en las condiciones del mercado. Precisan que una vez más la condición del mercado de cada empresa de alguna manera depende de la condición económica del país. Este estudio trabaja con los datos del volumen de acciones diarias de Dhaka Stock Exchange (DSE) para buscar modelos adecuados. Utilizan el diagrama de series temporales (en el nivel, en la primera diferencia, en la transformación logarítmica, en la transformación de suavizado y combinado de éstas) para describir el comportamiento de los datos. La gráfica de la serie de tiempo muestra que el volumen de acciones de DSE tiene una tendencia a la derecha a lo largo del tiempo, pero no la estacionalidad presente en la serie. La gráfica también indica que las series de volumen son heterocedásticas. Sin embargo, la trama de la serie de tiempo transformado de registro transgrede la tendencia original y no puede eliminar la variación irregular de la serie de datos. La serie transformada diferenciada muestra que la media es constante pero la varianza no es constante.

El objetivo final de este análisis econométrico fue encontrar un modelo adecuado que pronostique el volumen de acciones de DSE. Observando auto función de correlación (ACF) y función de autocorrelación parcial (PACF), un

Modelo Regresivo de Media Móvil Integrada (ARIMA) y se observa que existen eventos heterocedásticos. Para seleccionar la mejor clase de modelo de volatilidad, se aplican modelos de clase de heteroscedasticidad (ARCH) para la selección comparativa utilizando los criterios de información de Akike (AIC), el criterio de información de Baysian (BIC), y el valor R-cuadrado. Finalmente, se observa que los modelos de EGARCH son tranquilamente razonables. Por lo tanto, se han utilizado diferentes tipos de ARIMA con modelos EGARCH. También los autores exploraron un modelo estadístico adecuado tanto para los inversores como para los investigadores para resolver el futuro estimación del volumen de acciones utilizando datos de volúmenes de existencias diarios de Dhaka Stock Exchange (DSE). Los datos de volumen diario del 1 de junio de 2004 al 19 de abril de 2010 fueron recuperados del sitio web de DSE como una fuente de datos secundaria.

Los procedimientos utilizados: Método de máxima verosimilitud-autorregressiva condicional Heteroskedasticity (ARCH) que se aplicaron para construir los modelos para los datos de volúmenes de stock de DSE mediante software de paquete estadístico E-Views de versión-5. En primer lugar, instalaron un modelo "Auto Regressive Integrated Moving Average (ARIMA)" y observaron que todavía existían volatilidades heteroscedásticas. Para eliminar este dilema, usaron la clase ARCH de modelos de volatilidad y finalmente exploraron el modelo ARIMA con EGARCH. Los hallazgos de este estudio han reconocido que ARIMA con modelo EGARCH implica un error cuadrático medio bajo, un error absoluto medio bajo, una proporción de sesgo baja y una proporción de varianza baja para los datos de volumen compartido con respecto a otros modelos.

Los resultados obtenidos por los investigadores señalan que los diagramas mostraron los siguientes resultados: El gráfico de series de tiempo muestra que la proporción el volumen de la DSE tiene una tendencia a la derecha con el tiempo, pero la no estacionalidad presente en la serie; hay eventos heterocedásticos presentes en la serie. Sin embargo, la trama de la serie de tiempo transformado de registro transgrede la tendencia original y no puede eliminar la variación irregular de la serie de datos. La serie

transformada diferenciada muestra que la constante media pero la varianza no es constante. El método de suavizado resistente, 4253H-dos veces transformación trama serie muestra que hay ligeramente tendencia al alza en el tiempo y las variaciones irregulares reducir a partir de los datos del cuadro 1. Por lo tanto, suavizar las series de datos utilizado en todo el análisis. Para mostrar el estado estacionario de la serie, se utilizan las pruebas DF y ADF. DF y ADF sugieren que la serie de datos de volumen no diferenciados es insignificante y la serie de datos de volúmenes transformados diferenciados es altamente significativa al nivel de significación de 5% y 10%. Por lo tanto, la serie de datos de volumen no es estacionaria y después de diferencias no estacionales de la serie, tanto DF como ADF sugieren que la serie es estacionaria de acuerdo al siguiente cuadro en donde se muestras las pruebas de Dickey-Fuller (DF) y Dickey-Fuller aumentada (ADF) para pruebas de raíz unitaria:

Cuadro 2.1 **de Dickey-Fuller (DF) y Dickey-Fuller aumentada (ADF)**

DF and ADF Test of Volume Data Series (Y_t) and Differenced Transformed Volume Data Series (ΔY_t)

Data	Test	Test statistic (Prob.)	Asymptotic critical values at 5%	Asymptotic critical values at 10%
Y_t	DF	0.936619 (0.891)	-2.863242	-2.567724
	ADF	0.210989 (0.863)		
ΔY_t	DF	-7.087286 (0.000)		
	ADF	-11.28614 (0.000)		

Fuente. Datos tomados de Hossain, Kamruzzaman y Ali (2015)

El objetivo final de este estudio fue encontrar un modelo adecuado para proyectar la tendencia futura del volumen de acciones de DSE. Observando ACF y PACF, se ajusta un modelo ARIMA (1, 1, 1) (Figura 2.1) y se observa que todavía existen eventos heterocedásticos.

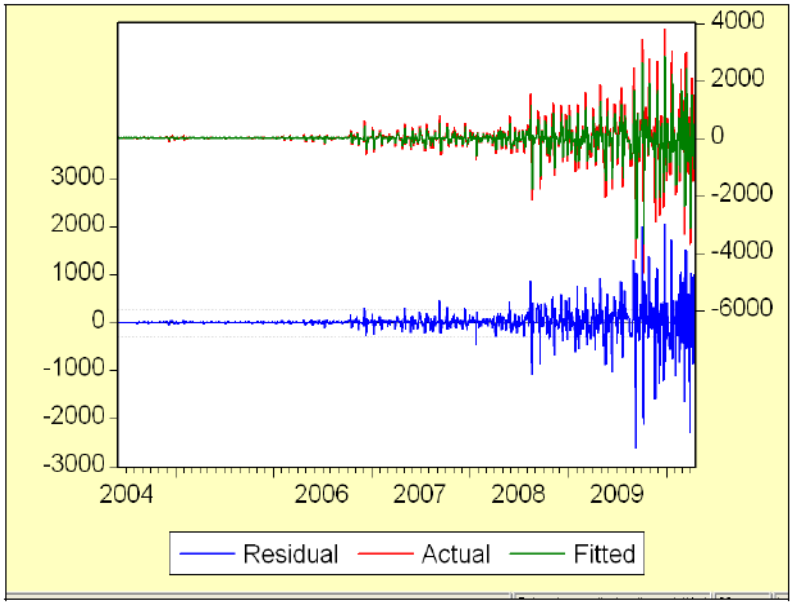

Figura 2.1 Gráfico de actual, ajustado y residual obtenida del modelo ARIMA (1,1,1)
Fuente. Hossain, Kamruzzaman y Ali (2015)

Los siguientes tres modelos tienen una interpretación interesante. Para cada modelo, los valores absolutos de los parámetros son menores que la unidad, lo que garantiza la condición de estacionariedad de los modelos. El R-cuadrado valor para el modelo 1 es 0.876470 lo que significa que el 87% de la variación en el volumen diario de datos se explica por el modelo 1; el valor R-cuadrado para el modelo 2 es 0,754143, lo que significa que el 75% de la variación en los datos de volumen diario se explica por el modelo 2, y el R-cuadrado para el modelo 3 es 0,885952, lo que significa que el 88% los datos se explican por el modelo 3. Por lo tanto, el valor R-cuadrado obtenido del modelo 3 es mayor que el del modelo 1 y el modelo 2. Por lo tanto, el modelo 3 debería ser el modelo mejor ajustado. Los valores R cuadrados observados para el modelo 1, modelo 2 y modelo 3 son 0,875658, 0,752688 y 0,885275. Los valores ajustados de R-cuadrado sugieren que la línea de regresión de la muestra se ajusta bien a los datos. Las gráficas reales, ajustadas y residuales obtenidas del modelo 1, modelo 2 y modelo 3 se han mostrado en figuras 2.2, 2.3 y 2.4. Se observa que el modelo 1 y el modelo 2 no encajan tan bien; el modelo 3 está bien montado, pero al final, hay una pequeña fluctuación. Por lo tanto, se puede concluir que el modelo 3 puede ser el modelo ajustado apropiado

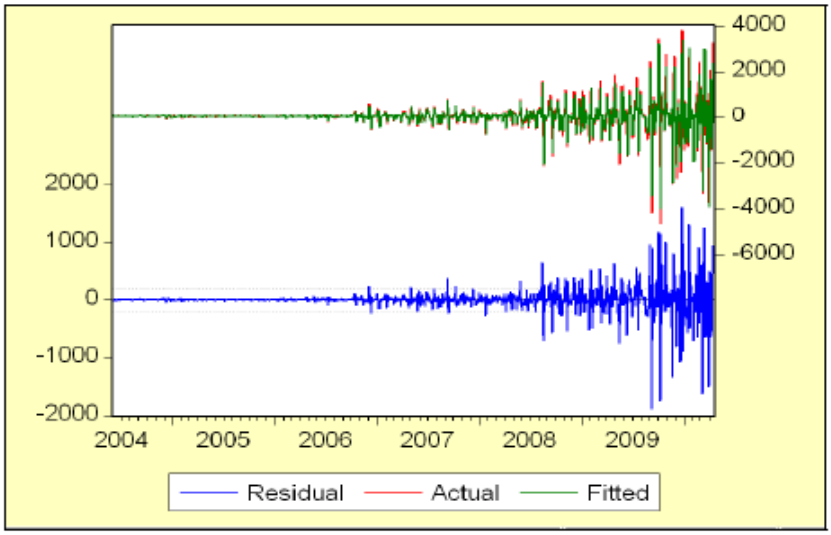

Figura 2.2 Gráfico actual, ajustado y residual obtenida del modelo 1
Fuente. Hossain, Kamruzzaman y Ali (2015)

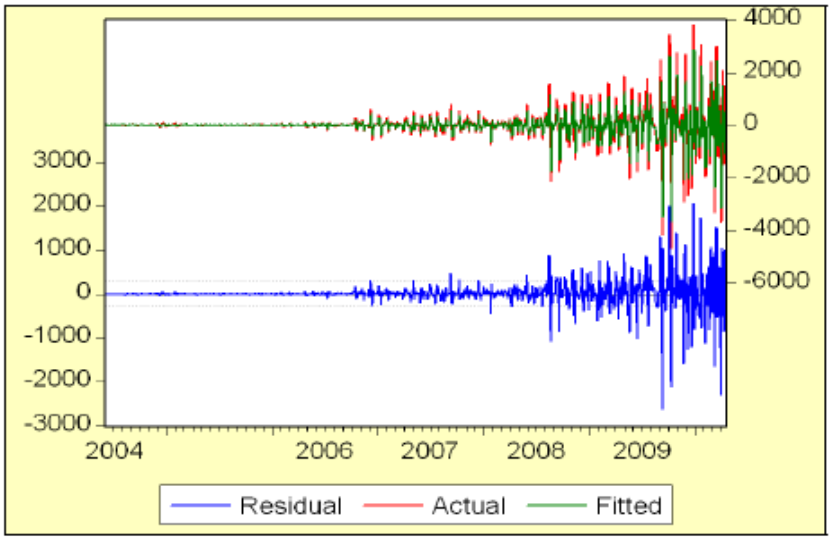

Figura 2.3 Gráfico actual, ajustado y residual obtenida del modelo 2
Fuente. Hossain, Kamruzzaman y Ali (2015)

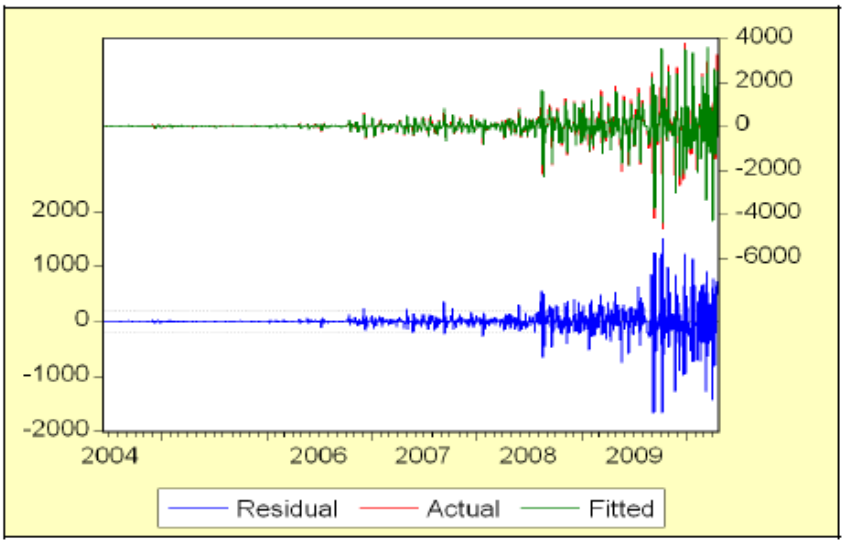

Figura 2.4 Gráfico actual, ajustado y residual obtenida del modelo 3
Fuente. Hossain, Kamruzzaman y Ali (2015)

En la investigación de De Jesús, Vergara, y Díaz (2015), los autores intentan evaluar el poder predictivo a través de modelos de la familia GARCH para predecir la volatilidad de los rendimientos de la Mezcla Mexicana de Exportación durante el periodo del 2 de enero de 1989 al 30 de diciembre de 2011. Los investigadores sostienen que el petróleo es un recurso energético no renovable y tiene importancia en el crecimiento económico del mundo, la estabilidad de los "mercados de derivados sobre activos subyacentes energéticos" y en los tiempos de la "crisis subprime y la euro-crisis de deuda soberana, los precios de contado del petróleo alcanzaron exorbitantes récords nunca antes observados, seguidos de fuertes rebotes a la baja tanto en el corto como en el mediano plazo", en sintonía con la reducción en la demanda por la recesión, que empezó en 2008. Asimismo, agregan que estas volatilidades ocasionaron niveles de asimetrías en los rendimientos de los precios del petróleo y que a su vez afectaron la confianza de los diversos consumidores y como resultados de las diversas crisis financieras, es de imperiosa necesidad describir y pronosticar las volatilidades en los precios del petróleo e indican que el mínimo error de pronóstico del nivel de volatilidad es vital como información pues permitirá la buena toma de decisiones financieras.

Explican que para responder a los cambios en la demanda de energía global, la disminución de la oferta de petróleo crudo en los lugares de origen,

las leyes de protección del medio ambiente, la presencia de posiciones ecologistas, han obligado a compradores de petróleo buscar nuevos mercados de energía de bajo costo y calidad pero de alto contenido de azufre, indican que aproximadamente el 50% de la producción mundial es petróleo de menor calidad y por tal razón, buscan evaluar los modelos GARCH al pronosticar la volatilidad, la ubicación de la heterocedasticidad condicional, "persistencia y la presencia de asimetría en la volatilidad de las innovaciones de la Mezcla Mexicana de Exportación durante el periodo del 2 de enero de 1989 al 30 de diciembre de 2011". También pretenden contribuir con su trabajo, el debate de este campo de "la investigación, proporcionando evidencia empírica del poder predictivo de la volatilidad empleando los modelos GARCH, IGARCH, EGARCH y GARCH-GJR (…) se analiza de dos maneras para los horizontes de predicción de 1, 5 y 20 días". Los autores "utilizaron los precios diarios de la Mezcla Mexicana de Exportación. (…) expresados en dólares estadounidenses y cubren el periodo del 2 de enero de 1989 al 30 de diciembre de 2011, para un total de 5968 observaciones". Estos datos fueron separados en dos submuestras: Volatilidad dentro de muestra por el periodo 1989-2007 donde se analizó la volatilidad dentro de muestra y en el periodo 2008-2011 se evaluó la fortaleza del poder predictivo fuera de muestra. "La serie de precios se obtuvo de la base de datos de Datastream".

El método de cuasi-máxima verosimilitud fue usado para estimar los resultados dentro de muestra con los modelos GARCH, debido a que posee errores mínimos de pronósticos y asume que los errores tienen una distribución normal. Los resultados se verifican en el cuadro 2.2 de la estimación de los parámetros y pruebas de diagnóstico. Al analizar la media se puede observar que todos los estimadores son estadísticamente significativos para los diferentes niveles de significancia, excepto para el modelo GARCH-GJR (1,1).

Cuadro 2.2 **Estimación de los parámetros y pruebas de diagnósticos**

Modelos	GARCH	IGARCH	EGARCH	GARCH-GJR
C	0,045***(0,0260)	0,063*(0,0181)	0,051**(0,0255)	0,041(0,0279)
ω	0,083*(0,0080)	-	-0,103*(0,0039)	0,088*(0,0088)
α	0,086*(0,0033)	0,065*(0,0020)	0,192*(0,0068)	0,072*(0,0042)
β	0,906*(0,0038)	0,934*(0,0020)	0,978*(0,0017)	0,905*(0,0039)
γ			-0,081*(0,0218)	0,026*(0,0058)
$\alpha+\beta$	0,992	1	1.711	0,978
Diagnóstico				
log(L)	-11001	-11069	-11006	-11000
AIC	2.201	2.214	2.202	2.201
BIC	2.203	2.215	2.205	2.204
$Q(10)$	7,186[0,7078]	7,001[0,7253]	6,221[0,7963]	6,159[0,7633]
ARCH(10)	9,698[0,4674]	13,874[0,1788]	8,244[0,6049]	9,906[0,4487]
$Q^2(10)$	9,776[0,4603]	14,302[0,1597]	7,112[0,7128]	9,921[0,4474]
$Q^2(12)$	22,381[0,0335]	16,800[0,1012]	23,431[0,0242]	22,273[0,0348]
Prueba de Engle y NG (1993)				
$\varnothing_0$	-1,143*(0,0434)			
$\varnothing_1$	-0,528*(0,0615)			
$\varnothing_2$	-3,683*(0,0418)			
$\varnothing_3$	2,944*(0,0447)			
LM	10.169			
Valor-p	0,017			
$\rho_{\eta_t^2,\eta_t}$	-0,229			

Fuente. Datos tomados de Jesús, Vergara, y Díaz (2015)

Con referencia a los parámetros de la ecuación de la varianza condicional, los modelos GARCH (1,1), IGARCH (1,1), EGARCH (1,1) y GARCH-GJR (1,1) logran identificar las características de la volatilidad condicional y sus respectivos patrones, así como la significancia estadística de sus estimadores.

En particular, los estimadores de los términos GARCH tienen valores positivos y caen en el rango 0,905-0,978, mientras que los coeficientes de los términos ARCH varían entre 0,065 y 0,192. Además, los valores del coeficiente de persistencia $\alpha + \beta$ se encuentran en el rango de 0,978-1,171, muy cerca de 1, lo que indica la presencia del componente de memoria larga en el proceso de la volatilidad. Este hecho favorece al modelo IGARCH (1,1) e implica que los choques en los rendimientos del petróleo tienen efectos permanentes y un alto grado de persistencia en la volatilidad, que desaparecen más lentamente a través del tiempo en proporción directa a una tasa hiperbólica que a una tasa de decaimiento exponencial. Por otra parte, pese a que el coeficiente de persistencia del modelo EGARCH (1,1) excede a 1, el proceso de la volatilidad continúa siendo estacionario y ergódico porque el valor absoluto del término GARCH se mantiene por debajo de 1; una

condición necesaria y suficiente sustentada por Nelson en 1991. De acuerdo con los efectos asimétricos, los parámetros estimados γ asociados con la volatilidad asimétrica son significativamente diferentes de cero para cualquier nivel de significancia en ambos modelos asimétricos, aunque relativamente pequeños en términos absolutos, particularmente en el modelo GARCH-GJR (1,1). Obviamente, este hallazgo muestra que los efectos de apalancamiento están presentes en el mercado del petróleo de la Mezcla Mexicana de Exportación porque los choques negativos o noticias malas suelen tener mayor impacto en la volatilidad que los choques positivos o noticias buenas de la misma magnitud. Desde un punto de vista económico, este fenómeno puede ser explicado a través de la figura 5, que presenta la predicción de la volatilidad condicional fuera de la muestra a través de los cuatro modelos GARCH, que es consistente con el comportamiento de la volatilidad actual (De Jesús, Vergara y Díaz, 2015, pp.17-19).

Durante el periodo 2008-2009 de la figura 2.5, se visualiza cómo el comportamiento asimétrico de los choques negativos y positivos como la depreciación del dólar estadounidense, particularmente contra el euro, y la recesión económica de los Estados Unidos y que impactó directamente en los mercados energéticos. También hay una correlación inversa entre el tipo de cambio nominal que se devaluó y el precio del petróleo que subió hasta niveles nunca visto en el pasado, que fue ocasionado por especulaciones en el mercado de las materias primas, que originó alta volatilidad. Pero la profundización de la crisis financiera mundial debido a los escases del crédito ocasionó la reducción en forma exponencial de los precios del petróleo y por consiguiente de la volatilidad en el mercado de la Mezcla Mexicana de Exportación. “Este fenómeno de volatilidad asimétrica volvió a ocurrir, con menor magnitud, en el periodo 2010-2011 debido al conflicto en Libia y a la crisis política en Medio Oriente, (..) la crisis griega y una nueva recesión en Estados Unidos” esto se aprecia en la figura 2.5.

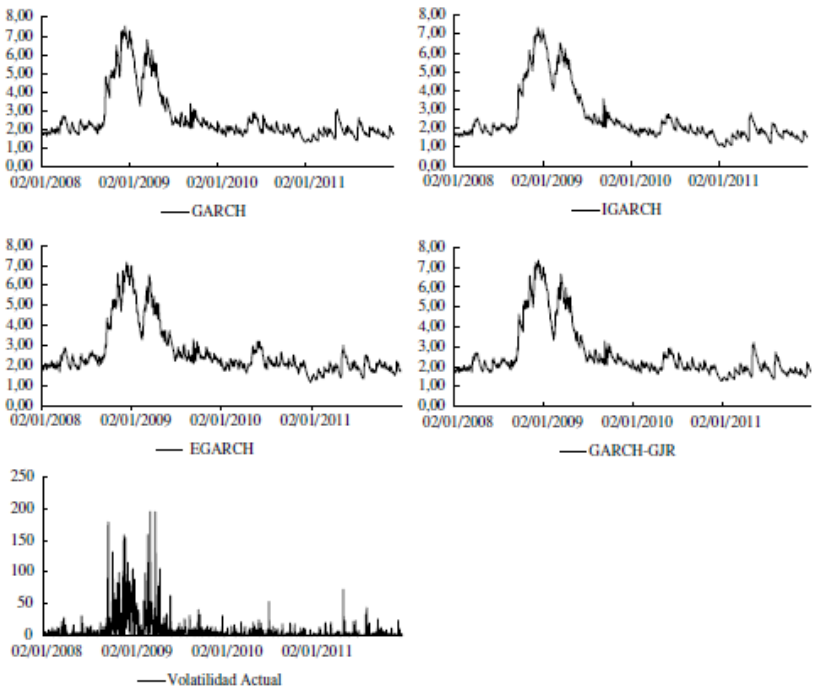

Figura 2.5 Predicción de la volatilidad condicional y volatilidad actual
Fuente. Jesús, Vergara, y Díaz (2015)

Asimismo, los investigadores para evaluar la performance de los modelos de volatilidad dentro de muestra, en términos absolutos consideraron los mínimos valores más pequeños de los indicadores Log(L), AIC y BIC reportados en el Cuadro 2.2. Los modelos GARCH (1,1) estándar y GARCH-GJR (1,1) tienen buenos resultados para considerar la heterocedasticidad condicional, la aglomeración o cluster de la volatilidad, la persistencia de las perturbaciones y el impacto del apalancamiento. El modelo EGARCH (1,1) también muestra su robustez después de los GARCH(1,1).

De acuerdo con la significancia de los valores del estadístico de la prueba de Ljung-Box con 10 rezagos, muestran evidencias significativas de la especificación de la ecuación de la media condicional y explica el comportamiento de los rendimientos de los precios del petróleo, en particular, los modelos EGARCH (1,1) y GARCH-GJR (1,1), y no se rechaza la hipótesis nula de que no existe correlación serial en los residuales estandarizados simples. Por su parte, la significancia de la prueba ARCH (10) también confirma la ausencia de evidencia estadística de efectos ARCH en los residuales estandarizados, mientras que la notable significancia de las pruebas de Ljung-Box con 10 rezagos sobre los residuales estandarizados

cuadrados indica el buen ajuste de los cuatro modelos de volatilidad para explicar la heterocedasticidad observada en el mercado del petróleo mexicano, demostrando que no hay evidencia estadística de error de especificación en los modelos GARCH univariados. Pero cuando todos los P valores de la prueba de Ljung-Box con 12 rezagos son menos del 5%, la ecuación de la varianza no será adecuado para modelar la volatilidad condicional de los rendimientos de la Mezcla Mexicana de Exportación. Pero el modelo IGARCH (1,1) si capturara adecuadamente la volatilidad con respecto a otros modelos (De Jesús, Vergara y Díaz, 2015, pp.20-21).

En otro artículo de investigación de Parody, Charris y García (2016), pretenden predecir el "precio de las acciones del sector bancario que se cotizan en el índice general de la Bolsa de Valores de Colombia (IGBC) para el período del 17 al 24 de julio de 2015". El problema inicial fue tomar la mejor decisión luego de evaluar los riesgos en el mercado financiero colombiano para comprar o vender acciones, esto permitirá reducir el impacto negativo de la volatilidad y la incertidumbre que preocupan a los inversionistas, "haciéndose necesario el cálculo de diferentes medidas de mitigación de riesgos y de pronósticos de las series, para diseñar estrategias financieras y de construcción de portafolios de inversiones".

Estos investigadores sostienen que hay dos enfoques de predicción opuestas, sosteniendo que una de estas considera la utilidad de la información histórica del precio de un activo financiero y su utilidad para su predicción debido a la presencia de patrones repetitivos. En contraparte, la teoría de los mercados eficientes y su comportamiento aleatorio sostienen la imposibilidad de predecir los precios de un activo financiero a partir de su historia o precios del antaño, dado su desenvolvimiento errático.

El propósito del artículo de investigación es predecir el "precio de las acciones del sector bancario que se cotiza en el índice general de la Bolsa de Valores de Colombia IGBC con la utilización del modelo Log-Normal y el uso de la simulación de Monte-Carlo", durante el período del 17 al 24 de julio de 2015. Con los estadísticos del error métrico cuadrado (MSE) y el error

porcentual absoluto medio (MAPE) se pretende determinar la fortaleza del modelo predictivo. Los datos se tomaron de los sitios Web www.grupoaval.com y www.bvc.com.co de los bancos analizados; los precios de cierre diario de las acciones del Banco de Colombia, Banco de Bogotá y Banco de Occidente, en el periodo de tiempo comprendido entre el 17 al 24 de julio de 2015. Con estos precios obtenidos se calcularon los retornos de cada serie bancaria por día haciendo uso de los logaritmos neperianos de los precios de hoy y los precios del día inmediato anterior con la siguiente fórmula: R1=ln(St)-ln(St-1). Con los resultados logrados se obtuvieron las medias (μ) y la varianzas (S^2) de las muestras de cada series en estudio, para ello, aplicaron las respectivas funciones de Excel, PROMEDIO() y VAR(). Luego simularon los "valores de Z como variables aleatorias tipo Z~N(0;1), generando números de una distribución uniforme (0,1)" con la función ALEATORIO de Excel para después de realizar una simulación con mil escenarios para cada día de interacción de las acciones de Bancolombia, Banco de Bogotá y Banco de Occidente se elaboraron mil escenarios por día en base a un proceso Browniano de tipo Markov para obtener una predicción puntual. Adicionalmente, se ejecutó una predicción por intervalos para tener umbrales de riesgo cuando se pronostican. Consideran además las Medidas de Bondad de Ajuste: Error Cuadrático Medio y Error Porcentual Absoluto Medio y finalmente los autores graficaron los resultados obtenidos.

Los resultados mostraron que la acción que más se ajusta al modelo de pronóstico desarrollado, es la del banco de Banco de Occidente, que en promedio el desvío entre los valores pronosticados y los reales es de 8,5361 y correspondientes al 0,1438%, lo que denota un buen modelo de pronóstico para este grupo de acciones, que es la menos volátil de los tres grupos de acciones estudiados; por lo cual se puede resaltar que si bien el modelo incorpora el factor aleatorio en la variable Z, aplicando las simulaciones, este no logra interpretar "todos los eventos que ocurren en el mercado, por tanto a los activos más volátiles se les otorga una menor capacidad predictiva" en la aplicación de estos modelos tal como se podrá verificar el siguiente cuadro:

Cuadro 2.3 **Resultados de las medidas de bondad de ajuste para cada grupo de acciones**

Medida de Bondad de Ajuste	Acción Bancolombia	Acción Banco de Bogotá	Acción Banco de Occidente
MSE	93,55186409	166,798073	8,5361669
MAPE	-2,130862123	1,59554402	0,14385543

Fuente. Tomado de Parody, Charris y García (2016)

Analizando el comportamiento del valor real de la acción del Banco de Occidente, se observa que el pronóstico es más efectivo que en las acciones anteriores, tal como lo corrobora las medidas de bondad de ajuste observadas en el cuadro 2.3, que resalta el hecho de ser una acción poco liquida y poco volátil, por lo que la media y la desviación de los rendimientos no cambian en gran proporción entre períodos de tiempo, por lo que genera un pronóstico más efectivo. El modelo puede servir como insumo para tener una aproximación a los posibles valores mínimos y máximos que puede tomar el activo financiero, sus resultados carecen de la suficiente precisión para inducir la compra certera de este tipo de activo financiero. Aunque en el modelo incorpora el factor aleatorio, aplicando las simulaciones, no es suficiente para capturar la capacidad predictiva de los instrumentos que tiene alta volatilidad, podrían tener menor capacidad predictiva; en este sentido el modelo evidenció mejores pronósticos para el precio de la acción del Banco de Occidente, que es la acción con menos volatilidad, tal como lo corrobora las medidas de bondad de ajuste, En consecuencia para las próximas investigaciones, los investigadores recomiendan la aplicación de modelos con promedios móviles de suavizamiento exponencial y modelos de la familia ARCH Y GARCH cuando se presenta volatilidad.

Tsakou (2016) en su tesis para optar el grado Doctoral de la Universidad de Stirling, de Escocia; Reino Unido, ingresó al debate para la predicción de modelos de volatilidad utilizando una serie de índices bursátiles estadounidenses y europeos, sostiene además que la volatilidad del mercado de valores ha sido una de las áreas de investigación más atractivas y exitosas en econometría de series de tiempo y economía financiera en los últimos años y añade que la volatilidad se ha convertido en una cuestión crucial no sólo para los inversores, sino también para casi cualquier persona que esté involucrada en los mercados financieros, incluso como espectador y que para ellos, la volatilidad es sinónimo de riesgo y la cantidad de volatilidad que tienen

que afrontar es un insumo clave para tomar decisiones sobre sus inversiones y creaciones de cartera. También agrega que el principal incentivo para la vasta investigación empírica y teórica centrada en la estimación y previsión de la volatilidad de la renta variable fue el colapso mundial del mercado bursátil de 1987. Se evidencia la necesidad de estimar y predecir la volatilidad siendo de suma importancia para cualquier persona que participe en el mercado financiero, ya que afecta a todo el sistema financiero y, en consecuencia, toda la economía. Modelar y predecir la volatilidad es una tarea importante en los mercados financieros y en los últimos tres decenios hay una extensa investigación que refleja el importante papel de la volatilidad en la inversión, la fijación de precios de opciones y la gestión de riesgos y por lo tanto, el objetivo de la tesis fue analizar la estimación precisa y la previsión de la volatilidad en el mercado financiero pues es un tema de crucial importancia y ha sido un tema popular de investigación sin conclusión general sobre qué modelo proporciona las previsiones más precisas. Esa tesis pretende determinar el modelo que mejor pronostica la volatilidad futura y en particular, examina el papel de los parámetros clave en la mejora del ajuste y pronóstico del rendimiento de varios modelos de volatilidad. A los efectos del análisis, la autora utiliza un extenso conjunto de datos de índices bursátiles estadounidenses y europeos para evaluar si los resultados pueden ser diferentes de un país a otro. El conjunto de datos utilizado para los propósitos de este estudio consistió en los datos de precios de cierre diarios de los índices S & P Composite 500 (S & P500), Dow Jones Industrial Average (DJIA) y Nasdaq100 y sus índices de volatilidad implícita VIX, VXD y VXN, respectivamente. Dado que los diversos índices de volatilidad implícita han sido listados en diferentes fechas, consideró el período comprendido entre el 2 de febrero de 2001 y el 28 de febrero de 2013 con el fin de estudiar los índices durante el mismo período. El período comprendido entre el 2 de febrero de 2001 y el 23 de febrero de 2010 consta de 2.363 observaciones diarias y las restantes 787 observaciones (del 24 de febrero de 2010 al 28 de febrero de 2013) se utilizaron para la evaluación fuera de la muestra. Tanto los retornos diarios ex post al cuadrado como la desviación realizada se usó como proxies para la verdadera volatilidad. Los datos de la varianza realizada se toman de Oxford-Man Institute's Realized Library versión 0.2.

Posteriormente, con las rentabilidades del índice bursátil, r_t, calculó las diferencias de los precios log, $r_t = \ln (Pt/P_{t-1})$. Sus resultados mostraron que la media de los retornos es constante y alrededor de cero, pero la varianza cambia con el tiempo mostrando evidencia de agrupación de volatilidad.

Una variación no constante de los rendimientos indica una distribución no normal. El cuadro 2.4 presenta la estadística descriptiva de los rendimientos del mercado de valores, la media y la mediana son consistentemente cercanas a cero. En cuanto a los valores de asimetría y curtosis, para una distribución normal, deben ser cero y tres, respectivamente. La asimetría negativa de todas las series indica distribuciones asimétricas sesgadas a la izquierda, mientras que las estadísticas de curtosis muestran la característica leptocúrtica de todas las distribuciones de retornos. La evidencia de la no-normalidad es apoyada por la estadística de la prueba de Jarque-Bera que rechaza la hipótesis nula de la distribución normal en el nivel del 1%. A continuación, se presenta el cuadro 2.4.

Cuadro 2.4 **Estadísticas de resumen para la muestra completa y retornos de las acciones diarias fuera de muestra**

a)	Full sample			b)	In-sample		
	S&P500	DJIA	Nasdaq100		S&P500	DJIA	Nasdaq100
Mean	3.80E-05	8.47E-05	3.37E-05	Mean	-9.18E-05	-2.41E-05	-0.0001
Median	0.0006	0.0004	0.0008	Median	0.0006	0.0004	0.0007
Maximum	0.1095	0.1051	0.1185	Maximum	0.1096	0.1051	0.1185
Minimum	-0.0947	-0.0820	-0.1111	Minimum	-0.0947	-0.0820	-0.1111
Std. Dev.	0.0134	0.0125	0.0180	Std. Dev.	0.0139	0.0131	0.0194
Skewness	-0.1704	0.0328	0.0592	Skewness	-0.1118	0.1148	0.1001
Kurtosis	11.049	10.778	7.3248	Kurtosis	11.420	10.981	6.7772
Jarque-Bera	8223.4	7666.2	2371.7	Jarque-Bera	6740.0	6056.5	1359.2
p-value	0.0000*	0.0000*	0.0000*	p-value	0.0000*	0.0000*	0.0000*

Fuente. Datos tomados de Tsakou (2016).

De manera similar, el cuadro 2.5 muestra las estadísticas de resumen de los índices IV junto con la prueba de Dickey-Fuller (ADF) aumentada para raíces unitarias. Los p-valores de las pruebas ADF muestran que los índices de volatilidad implícita son estacionarios a niveles convencionales. Los índices IV miden las expectativas del mercado en los próximos 30 días calendario. Así, los índices IV se expresan en porcentajes anualizados. Por lo tanto, siguiendo a Blair et al. (2001), la volatilidad implícita diaria del índice es igual a $IV/100*\sqrt{252}$.

Cuadro 2.5 **Estadísticas de resumen para los índices de volatilidad implícita**

	VIX	VXD	VXN
Mean	0.0137	0.0127	0.0179
Median	0.0123	0.0115	0.0150
Maximum	0.0509	0.0470	0.0508
Minimum	0.0062	0.0058	0.0079
Std. Dev.	0.0060	0.0056	0.0082
Skewness	1.9049	1.8183	1.2459
Kurtosis	8.4758	7.8965	3.7623
Jarque-Bera	5640.3	4715.2	860.67
p-value	0.0000*	0.0000*	0.0000*
ADF (p-value)	0.0051*	0.0091*	0.0113**

Fuente. Datos tomados de Tsakou (2016).

Los resultados de la muestra que se visualizan en el cuadro 2.6 expone las estimaciones de los parámetros de los modelos GARCH alternativos. Las estimaciones de GARCH muestran que todos los coeficientes de la ecuación de varianza (α_0, α_1, y β_1) son estadísticamente significativos a un nivel de 1% y satisfacer las restricciones de no negatividad. La suma α_1,+β_1 es menor que uno, pero muy cercana a uno, lo que implica que los choques de la volatilidad tienen un efecto altamente persistente sobre la varianza condicional. En cuanto a los resultados del modelo GARCH-IV, que añade la volatilidad implícita como una variable exógena en la ecuación de la varianza condicional, encontró que todos los índices el parámetro θ IV son significativos al 1%. La prueba de razón de verosimilitud rechaza la hipótesis nula de que la volatilidad implícita no contiene información incremental útil para explicar la varianza condicional.

Cuadro 2.6 **Modelos de estimación de la familia Garch**

Table 4: Estimation models of the GARCH family

	GARCH	*GARCH − IV*	*GJR*	*GJR − IV*	*EGARCH*	*EGARCH − IV*	*CGARCH*	*CGARCH −IV*	*ACGARCH*	*ACGARCH −IV*
					S&P500					
α_0	1.08×10^{-6}** (0.020)	-1.37×10^{-5}** (0.012)	9.06×10^{-7}* (0.000)	4.37×10^{-7} (0.269)	−0.18015* (0.000)	−0.00584 (0.919)	0.00016*** (0.068)	-8.43×10^{-6} (0.418)	0.00015* (0.009)	-1.26×10^{-5}* (0.007)
α_1	0.07416* (0.000)	−0.04184*** (0.086)	−0.02695** (0.012)	−0.05644* (0.000)	0.08435* (0.000)	0.00884 (0.807)	0.00244 (0.353)	−0.08964* (0.000)	−0.14559* (0.000)	−0.01220 (0.463)
β_1	0.91892 * (0.000)	−0.06396 (0.799)	0.95343* (0.000)	0.90724 * (0.000)	0.98754* (0.000)	0.87468 * (0.000)	−0.99442* (0.000)	0.19152 (0.275)	0.66490* (0.000)	0.08828 (0.946)
γ			0.13144* (0.000)	0.18280* (0.000)	−0.11406* (0.000)	−0.19229* (0.000)			0.06728 (0.216)	0.05027 (0.361)
ρ							0.99349* (0.000)	0.97684* (0.000)	0.98790* (0.000)	0.03837 (0.977)
ϕ							0.07334* (0.000)	0.03265* (0.000)	0.10462* (0.000)	−0.04816 (0.871)
θ		0.86531* (0.000)		0.03889* (0.000)		0.13150* (0.000)		0.76574* (0.000)		0.70726** (0.020)
$Log - L$	7133.993	7177.89	7185.029	7199.599	7178.78	7202.876	7135.571	7198.065	7144.343	7179.536
χ^2	87.79	–	29.14	–	48.19	–	126.16	–	70.39	–
					DJIA					
α_0	1.10×10^{-6}** (0.009)	-8.73×10^{-6}*** (0.081)	9.91×10^{-7}* (0.000)	-3.45×10^{-7} (0.483)	−0.19593* (0.000)	−0.06522 (0.233)	0.000142** (0.010)	-3.54×10^{-6} (0.633)	0.00013* (0.009)	-4.53×10^{-6}* (0.000)
α_1	0.07787* (0.000)	−0.04274* (0.000)	−0.01647 (0.229)	−0.04959* (0.000)	0.09728* (0.000)	0.03378 (0.253)	−0.10033* (0.000)	−0.09671* (0.000)	−0.17666* (0.000)	−0.12228** (0.030)
β_1	0.91451 * (0.000)	−0.08851 (0.471)	0.94073* (0.000)	0.88927 * (0.000)	0.98704* (0.000)	0.89445 * (0.000)	0.54646* (0.004)	0.05205 (0.758)	0.59917* (0.000)	0.15721 (0.393)
γ			0.13532* (0.000)	0.18267* (0.000)	−0.11315* (0.000)	−0.17441* (0.000)			0.11191* (0.003)	0.06680** (0.042)
ρ							0.98804* (0.000)	0.96711* (0.000)	0.98896* (0.000)	0.96339* (0.000)
ϕ							0.1010* (0.000)	0.02895* (0.003)	0.09750* (0.000)	0.03257* (0.000)
θ		0.87797* (0.000)		0.04918* (0.000)		0.10574* (0.000)		0.81980* (0.000)		0.74265* (0.000)
$Log - L$	7233.753	7281.437	7278.800	7296.655	7279.334	7301.833	7242.652	7297.520	7248.263	7302.492
χ^2	95.37	–	35.71	–	45.00	–	109.74	–	108.46	–
					Nasdaq100					
α_0	1.14×10^{-6}** (0.029)	-1.66×10^{-5}*** (0.073)	1.04×10^{-6}** (0.013)	-2.63×10^{-7} (0.843)	−0.12253* (0.000)	0.06063 (0.433)	−0.00219 (0.942)	-1.26×10^{-5} (0.258)	0.000299 (0.109)	-1.57×10^{-5} (0.282)
α_1	0.05582* (0.000)	−0.02184 (0.442)	−0.00811 (0.363)	−0.03667*** (0.055)	0.07336* (0.000)	−0.01776 (0.624)	0.01046 (0.439)	−0.04893 (0.104)	−0.08887* (0.008)	−0.06980** (0.044)
β_1	0.94013 * (0.000)	−0.04489 (0.887)	0.95980* (0.000)	0.83725 * (0.000)	0.99234* (0.000)	0.76755 * (0.000)	0.95099* (0.000)	0.09177 (0.711)	0.35552 (0.322)	0.42994 ** (0.032)
γ			0.08657* (0.000)	0.14345* (0.000)	−0.07811* (0.000)	−0.76755* (0.000)			0.04185 (0.348)	0.09627*** (0.076)
ρ							0.99999* (0.000)	0.97961* (0.000)	0.99516* (0.000)	0.98051* (0.000)
ϕ							0.05269* (0.000)	0.01848** (0.032)	0.06868* (0.000)	0.02152** (0.021)
θ		0.89134* (0.000)		0.10058* (0.007)		0.24650* (0.001)		0.82964* (0.000)		0.54522* (0.005)
$Log - L$	6273.628	6315.092	6300.433	6317.492	6303.448	6328.670	6272.703	6323.778	6279.973	6325.611
χ^2	82.93	–	34.12	–	50.44	–	102.15	–	91.28	–

Fuente. Datos tomados de Tsakou (2016).

En los modelos GJR y GJR-IV, $\alpha_1 + \gamma > 0$ para todos los índices que indican que las malas noticias aumentan la volatilidad condicional más que las buenas noticias α_1. A diferencia de la restricción habitual del modelo GJR, $\alpha_1 < 0$ para todas las series en ambos modelos. No obstante, la restricción de la volatilidad incondicional positiva ($\alpha_1 + \beta_1 + 1/2\gamma$) todavía se mantiene. Cuando se añade la información de volatilidad implícita, la probabilidad de logaritmo es significativamente más alta que en GJR.

El impacto de la volatilidad implícita en la volatilidad condicional también se puede encontrar comparando el modelo EGARCH con su especificación EGARCH-IV. Se encontró que el coeficiente de los índices IV rezagados era estadísticamente significativo al nivel del 1%. Similar a los resultados de los modelos anteriores, el examen de razón de verosimilitud muestra que los datos del índice de volatilidad implícita tienen un poder explicativo incremental para la volatilidad condicional. Examinar el efecto asimétrico de las noticias; las negativas y significativas tanto en EGARCH como en EGARCH-IV muestran la existencia de un efecto de apalancamiento en los retornos.

En los modelos CGARCH y CGARCH-IV, la condición $\alpha_1 + \beta_1 < \rho < 1$ es válida para todos los índices, lo que implica que la volatilidad condicional de retorno del índice de largo plazo disminuirá más lentamente que el componente transitorio de la volatilidad. Este resultado sugiere además que la volatilidad permanente controla la volatilidad condicional. Se encontró que el coeficiente de los índices IV retardados era estadísticamente significativo al nivel del 1%.

Los modelos ACGARCH y ACGARCH-IV pretenden capturar la memoria larga característica de los retornos. La volatilidad condicional muestra la existencia de componentes tanto transitorios como permanentes. La volatilidad asimétrica transitoria es captada por y la característica de efecto de apalancamiento se mantiene. Además, la condición $\alpha_1 + \beta_1 + 1/2\gamma < \rho < 1$ se mantiene en ambos modelos para todos los índices, lo que implica que la volatilidad condicional del retorno del índice de largo plazo disminuirá más

lentamente que el componente transitorio de la volatilidad. Una vez más, la "prueba de razón de verosimilitud" muestra la utilidad de la volatilidad implícita. Las pruebas diagnósticas en los residuos estandarizados se realizan para todas las especificaciones alternativas de GARCH. Se espera que los residuos estandarizados tengan parámetros de asimetría y curtosis cercanos a los de una distribución normal, así como que no tengan efectos ARCH no modelados restantes. Como se hace referencia al cuadro 2.7, los resultados de las pruebas de diagnóstico indican que los residuos estandarizados están sesgados a la izquierda, mientras que los valores de curtosis y la prueba de Jarque-Bera han disminuido notablemente en valores absolutos para todas las series en comparación con las estadísticas de la serie de regresos originales del cuadro 2.7. Así, se puede inferir que todos los modelos son capaces de explicar la asimetría y las características de las distribuciones de retorno en cierta medida. Con la excepción del modelo GARCHIV y ACGARCH-IV en el índice S & P500, GARCH-IV en el DJIA y EGARCH-IV en Nasdaq100, las estadísticas de Ljung-Box Q (m) indican que las autocorrelaciones de los residuos son estadísticamente insignificantes en el nivel del 1% para todos los modelos de la familia GARCH. Por lo tanto, la hipótesis nula de no autocorrelación no es rechazada.

Cuadro 2.7 **Pruebas diagnósticos en residuos estandarizados al cuadrado**

	Skewness	Kurtosis	Jarque-Bera	Q(7)	LM(7)
			S&P500		
GARCH	−0.3185	4.1268	159.17 (0.000)	5.569 (0.591)	5.648 (0.581)
GARCH-IV	−0.3739	4.1484	178.42 (0.000)	16.799* (0.019)	16.039** (0.025)
GJR	−0.3374	3.9274	124.95 (0.000)	8.600 (0.283)	8.958 (0.256)
GJR-IV	−0.3711	4.1599	180.14 (0.000)	10.130 (0.181)	10.649 (0.155)
EGARCH	−0.4015	4.2664	213.62 (0.000)	8.279 (0.309)	8.629 (0.208)
EGARCH-IV	−0.4196	4.1792	199.01 (0.000)	11.007 (0.138)	11.934 (0.103)
CGARCH	−0.3101	4.0811	147.58 (0.000)	5.744 (0.570)	5.786 (0.565)
CGARCH-IV	−0.3784	4.0548	160.10 (0.000)	1.256 (0.990)	1.293 (0.989)
ACGARCH	−0.3436	4.1139	162.74 (0.000)	1.866 (0.967)	1.904 (0.965)
ACGARCH-IV	−0.3906	4.1927	193.11 (0.000)	17.273** (0.016)	16.911** (0.018)
			DJIA		
GARCH	−0.2706	4.1045	143.72 (0.000)	7.872 (0.344)	7.751 (0.355)
GARCH-IV	−0.3188	3.9265	120.17 (0.000)	15.995** (0.025)	15.523** (0.030)
GJR	−0.2835	3.9357	113.73 (0.000)	8.042 (0.329)	8.097 (0.324)
GJR-IV	−0.3079	4.0607	142.92 (0.000)	9.008 (0.252)	9.151 (0.242)
EGARCH	−0.3217	4.0930	152.84 (0.000)	7.282 (0.400)	7.361 (0.392)
EGARCH-IV	−0.3134	3.8984	115.20 (0.000)	10.436 (0.165)	10.861 (0.145)
CGARCH	−0.2809	4.0226	129.31 (0.000)	3.989 (0.781)	4.006 (0.779)
CGARCH-IV	−0.3333	3.9386	125.91 (0.000)	2.029 (0.958)	2.023 (0.959)
ACGARCH	−0.3138	4.1584	164.89 (0.000)	3.041 (0.881)	3.074 (0.878)
ACGARCH-IV	−0.3359	3.9431	127.35 (0.000)	2.162 (0.950)	2.176 (0.950)
			Nasdaq100		
GARCH	−0.1271	3.6512	46.42 (0.000)	7.137 (0.415)	7.171 (0.411)
GARCH-IV	−0.1776	3.4726	32.32 (0.000)	11.641 (0.113)	11.548 (0.116)
GJR	−0.1891	3.4943	36.80 (0.000)	10.934 (0.142)	11.024 (0.138)
GJR-IV	−0.1836	3.4803	34.73 (0.000)	11.437 (0.121)	11.514 (0.118)
EGARCH	−0.2263	3.5187	45.02 (0.000)	11.457 (0.120)	11.713 (0.110)
EGARCH-IV	−0.2282	3.5177	45.25 (0.000)	14.750** (0.039)	15.207** (0.033)
CGARCH	−0.1406	3.6793	51.34 (0.000)	7.544 (0.374)	7.528 (0.376)
CGARCH-IV	−0.1672	3.3971	25.61 (0.000)	5.237 (0.631)	5.0532 (0.654)
ACGARCH	−0.1284	3.5689	37.01 (0.000)	2.163 (0.950)	2.149 (0.951)
ACGARCH-IV	−0.1746	3.4103	27.57 (0.000)	5.933 (0.548)	5.849 (0.558)

Fuente. Datos tomados de Tsakou (2016).

Finalmente, con el fin de comprobar si hay residuos de ARCH en los residuos, se lleva a cabo el LM. Si las ecuaciones de la varianza condicional se especifican correctamente, no debe haber ningún efecto ARCH en los residuos estandarizados. De hecho, como se puede ver en el cuadro 2.8, la hipótesis nula de ningún efecto ARCH no puede ser rechazada al nivel del 1% con la excepción del modelo GARCH-IV y ACGARCH-IV en el índice S & P500, GARCH-IV en el índice DJIA y EGARCH-IV en el índice Nasdaq100. La Tabla 6 resume los coeficientes de los modelos AR (FI) MA (X) y sus p-valores para todos los índices. Los términos AR (1) y MA (1) son estadísticamente significativos al nivel de 1% para todos los modelos, excepto la especificación ARFIMAX para el índice VIX. Los coeficientes de r_t^+ t y r_t^- son también estadísticamente significativos al nivel del 1%. Además, el coeficiente de r_t^- es mayor en valores absolutos que los coeficientes de r_t^+ para todos los

modelos. Es evidente que hay efectos asimétricos contemporáneos para todas las estimaciones. En otras palabras, los rendimientos negativos influyen en los índices de volatilidad implícitos más que en los retornos positivos. Las ganancias negativas y positivas del índice bursátil hacen que el índice IV se mueva asimétricamente en la dirección opuesta. Es decir, los retornos contemporáneos positivos disminuyen la volatilidad implícita, mientras que los retornos contemporáneos negativos aumentan la volatilidad implícita y, por tanto, el nivel del índice. El parámetro de diferencia d en los modelos ARFIMA es significativo a nivel de 1% y $d \in (0,0.5)$ para todas las series indicando que los procesos presentan memoria larga. Sobre la base de la log-verosimilitud, los modelos de ARMA sin restricciones, estos que permiten la asimetría, superan a sus contrapartes restringidas. En general, dentro de la muestra, la especificación ARMAX funciona mejor para los índices VIX y VXD y la especificación ARIMAX para el índice VXN.

Cuadro 2.8 **Estimación de los resultados de los modelos de series temporales para la predicción volátil implícita**

	ARMA	ARMAX	ARIMA	ARIMAX	ARFIMA	ARFIMAX
			VIX			
c_0	0.01383^{+} (0.000)	0.01374^{+} (0.000)	$-1.85 * 10^{-7}$ (0.991)	$-4.64 * 10^{-7}$ (0.982)	0.01457 (0.440)	0.01454 (0.436)
$AR(1)$	0.98932^{+} (0.000)	0.98813^{+} (0.000)	0.56069^{+} (0.000)	-0.44888^{+} (0.000)	0.89105^{+} (0.000)	0.71781^{+} (0.000)
$MA(1)$	-0.14282^{+} (0.000)	0.15798^{+} (0.000)	-0.70967^{+} (0.000)	0.59274^{+} (0.000)	-0.59004^{+} (0.000)	-0.06291 (0.124)
d					0.49314^{+} (0.000)	0.49651^{+} (0.000)
r_t^{+}		-0.02337^{+} (0.000)		-0.02331^{+} (0.000)		-0.02323^{+} (0.000)
r_t^{-}		-0.04256^{+} (0.000)		-0.04160^{+} (0.000)		-0.04284^{+} (0.000)
$Log-L$	12332.11	12914.04	12338.69	12910.83	12317.91	12874.81
			VXD			
c_0	0.01291^{+} (0.000)	0.01288^{+} (0.000)	$-2.81 * 10^{-7}$ (0.985)	$-4.99 * 10^{-7}$ (0.978)	0.01350 (0.447)	0.01323 (0.347)
$AR(1)$	0.99098^{+} (0.000)	0.99029^{+} (0.000)	0.43836^{+} (0.000)	-0.67812^{+} (0.000)	0.91920^{+} (0.000)	0.81770^{+} (0.000)
$MA(1)$	-0.18672^{+} (0.000)	0.05046^{+} (0.000)	-0.61659^{+} (0.000)	0.74711^{+} (0.000)	-0.65026^{+} (0.000)	-0.28437^{+} (0.000)
d					0.49199^{+} (0.000)	0.49335^{+} (0.000)
r_t^{+}		-0.02607^{+} (0.000)		-0.02602^{+} (0.000)		-0.02566^{+} (0.000)
r_t^{-}		-0.03674^{+} (0.000)		-0.03557^{+} (0.000)		-0.03733^{+} (0.000)
$Log-L$	12590.77	13097.63	12590.79	13095.62	12579.71	13064.72
			VXN			
c_0	0.01978^{+} (0.000)	0.01973^{+} (0.000)	$-9.27 * 10^{-6}$ (0.60)	$-9.57 * 10^{-6}$ (0.655)	0.02128 (0.320)	0.02127 (0.324)
$AR(1)$	0.99405^{+} (0.000)	0.99373^{+} (0.000)	0.73707^{+} (0.000)	-0.63943^{+} (0.000)	0.86512^{+} (0.000)	0.79548^{+} (0.000)
$MA(1)$	-0.05258^{+} (0.000)	0.10309^{+} (0.000)	-0.80766^{+} (0.000)	0.74476^{+} (0.000)	-0.45675^{+} (0.000)	-0.21329^{+} (0.000)
d					0.49423^{+} (0.000)	0.49583^{+} (0.000)
r_t^{+}		-0.01351^{+} (0.000)		-0.01367^{+} (0.000)		-0.01352^{+} (0.000)
r_t^{-}		-0.02111^{+} (0.000)		-0.02041^{+} (0.000)		-0.02118^{+} (0.000)
$Log-L$	12418.49	12702.3	12421.5	12707.57	129397.01	12666.19

Fuente. Datos tomados de Tsakou (2016).

So (2016), para optar el título de Doctor en la Universidad de Minnesota, intenta analizar la estructura de dependencia de los rendimientos diarios de los activos financieros coreanos usando un enfoque de modelado integrado, combinando los modelos GARCH con la Teoría del Valor Extremo (EVT) y los métodos de copulación para investigar propiedades de activos individuales y propiedades multivariadas. sostiene que los inversores quieren evitar pérdidas catastróficas en los mercados financieros, pues han sido testigos de grandes fluctuaciones en los mercados financieros luego de que el mercado bursátil estadounidense se desplomara en 1987, la crisis financiera asiática en 1997, la burbuja de Internet en 2000 y la crisis hipotecaria subprime en 2007. En cada caso, se han generalizado. Las perturbaciones en un mercado o país se han transmitido fácilmente a otros mercados o países debido en parte al desarrollo de tecnologías de información y comunicación mejoradas. Por lo tanto, medir con exactitud y gestionar el riesgo de cartera asociado con los activos financieros de negociación se ha convertido en una parte indispensable de una estrategia global de inversión para controlar las pérdidas y en general, el riesgo de la cartera surge debido a fluctuaciones bruscas inesperadas de los precios (y las tasas de rendimiento implícitas) en las carteras de activos financieros. Las dos fuentes principales son: las contribuciones al riesgo de cada activo financiero por separado y las contribuciones al riesgo atribuibles a la interdependencia de los precios y los rendimientos entre los activos que componen la cartera de inversiones. Cuando se mide o gestiona la exposición al riesgo, es necesario que los inversores identifiquen las propiedades de riesgo de cada activo y la dependencia entre los activos. La literatura de finanzas ha propuesto que los inversionistas evalúen el valor en riesgo (VaR) y el déficit esperado (ES) de sus inversiones, En este caso, el VaR se refiere a la pérdida máxima esperada en un horizonte determinado bajo condiciones normales de mercado dentro de un intervalo de confianza dado. El ES es una medida de riesgo alternativo que mide la expectativa condicional de pérdida dado que la pérdida está más allá del nivel umbral de VaR y combina aspectos del método VaR con más información sobre el distribución de los retornos en la cola La principal crítica del VaR es que no es una medida de riesgo coherente y que una medida de riesgo coherente es una función que satisface cuatro

propiedades: homogeneidad, monotonicidad, condiciones libres de riesgo y subaditoriedad, pero el VaR viola algunos de estos axiomas, otra deficiencia grave del VaR es que sólo proporciona un número único, que no captura la cantidad de las pérdidas esperadas más allá de un nivel de confianza dado. La literatura de finanzas sostiene que es importante para estimar con exactitud y consistentemente estas medidas de riesgo. Si la exposición al riesgo no se calcula correctamente, una medida incorrecta podría dar lugar a una mala asignación de activos, a una falta de diversificación adecuada del riesgo ya pérdidas financieras significativas. El autor dice que en estudios anteriores han demostrado que las copulas son un medio eficaz para analizar la estructura de dependencia entre los activos financieros en un contexto constante y en un contexto que varía en el tiempo, también analiza la estructura de dependencia de los rendimientos diarios de los activos financieros coreanos usando un enfoque de modelado integrado. Este enfoque combina los modelos GARCH con la Teoría del Valor Extremo (EVT) y los métodos de copulación para investigar propiedades de activos individuales y propiedades multivariadas. El investigador encuentra que los datos de las rentas financieras no están distribuidos normalmente contra el supuesto clásico de la distribución normal. Para estas situaciones desarrolla modelos GARCH para pronosticar y capturar hechos comunes sobre volatilidad condicional (por ejemplo, colas gordas, persistencia de volatilidad y agrupación, asimetría y efectos de apalancamiento). Utiliza modelos GARCH para estimar la volatilidad condicional y EVT para estimar las colas de la distribución de errores de los rendimientos diarios durante 2000-2013.

La muestra tomada incluye los activos de la cartera incluyen: acciones de Samsung Electronics, futuros KOSPI200, futuros de dólar estadounidense y bonos del Tesoro de tres años. El investigador emplea modelos GARCH para estimar la volatilidad condicional y EVT para estimar las colas de la distribución de errores de los rendimientos diarios durante 2000-2013, los procedimientos que el autor sostiene fue que la literatura de finanzas demuestra claramente que los datos de las series temporales financieras muestran autocorrelación, heteroscedasticidad, agrupación de la volatilidad (Bollerslev, 1986) y efectos de apalancamiento. Estudios que ignoran estas

características seguramente medirían el riesgo de forma incorrecta. y las estrategias que utilizan esas estimaciones de la exposición al riesgo recomendarían insuficientes reservas de capital para absorber choques adversos, Aunque varios modelos generales autorregresivos condicionalmente heterocedásticos (GARCH) han sido utilizados para describir con mayor precisión la distribución condicional de los datos financieros, estos métodos pueden no ser suficientes para capturar completamente las distribuciones de cola extremadamente sesgadas o gordas de los rendimientos de los activos. En el contexto de la estimación del VaR, la especificación precisa y la identificación de la probabilidad de un movimiento extremo en el valor de un activo individual (o cartera) es esencial para la evaluación del riesgo. Por su naturaleza, los eventos extremos están relacionados con las colas de la distribución subyacente y varios estudios, después del trabajo pionero de Mandelbrot (1963), indican que las distribuciones de la mayoría de las series de tiempo financiero son de cola gorda. La investigación realizada aquí aborda cuatro áreas problemáticas. En primer lugar, propongo utilizar el método regular de la copulación de la vid con parámetros variables en el tiempo, como sugiere Patton (2006). Los modelos de copula se han aplicado ampliamente donde la densidad marginal se obtiene a partir de una CDF empírica. Esto me permite considerar medidas de dependencia más generales y flexibles, así como evitar la especificación errónea de un modelo GARCH, al enfocarse en las propiedades de las series temporales financieras (asimetría, exceso de curtosis y dependencia asimétrica).

En segundo lugar, el enfoque de copulación con variación temporal, relacionado con el mercado financiero coreano, se ha aplicado principalmente a funciones de copulación bivariadas (dos activos), no a conjuntos de datos dimensionales superiores a activos financieros como un índice bursátil o el tipo de cambio. La investigación se centra en un mercado financiero más diverso donde varios activos pueden ser positiva, negativa o débilmente correlacionados, y donde los inversores quieren entender la estructura de dependencia que varía en función del tiempo de los rendimientos de los activos.

En tercer lugar, en comparación con los estudios anteriores relacionados con el mercado financiero coreano, la investigación considera más períodos de tiempo. Los estudios anteriores se centraron en cómo un solo choque externo afectó la estructura de la dependencia del mercado coreano. Sin embargo, ahora se tuvieron más datos diarios para investigar dos tipos diferentes de choques (un choque doméstico en Corea durante 2002 y dos choques externos en 2008 y 2012). Analizó si estos shocks son diferentes en términos de los efectos resultantes sobre la estructura de dependencia de los activos. También determinó si el enfoque integrado es útil para investigar cómo la estructura de dependencia cambia con el tiempo.

Cuarto, al permitir que la relación de dependencia siga un proceso ARMA restringido (como en Patton 2006), identificó la no linealidad en la estructura de dependencia. La investigación estándar sobre el cálculo del VaR y del ES se ha centrado en la distribución de los retornos para un único activo, lo que limita la pertinencia de esos estudios para la evaluación del riesgo de la cartera. En contraste con la investigación anterior, la autora propuso analizar el riesgo de la cartera mediante el desarrollo de metodologías VaR y ES que utilizan los métodos GARCH-EVT-Time-Varying Copula. Este es el enfoque totalmente integrado que propuso utilizar en esta investigación y sostenió que se trata de un enfoque superior para la evaluación del riesgo de la cartera. Para ello, se utilizó una función de copulación bien ajustada utilizando datos de períodos separados para explicar las innovaciones en la estructura de dependencia de las carteras financieras alternativas. Con los resultados obtenidos por el investigador, buscó explorar un enfoque integrado para evaluar la exposición al riesgo financiero. Este enfoque incorpora modelos de cópula para investigar la estructura de dependencia no lineal y asimétrica de los activos financieros.

Su primer subobjetivo fue revisar la literatura de investigación aplicada relacionada con el uso de los métodos GARCH, EVT y Copula para cargar la evaluación del riesgo con el propósito de identificar desarrollos importantes en la literatura aplicada. Identifico dos desarrollos de este tipo en la literatura de investigación.

En primer lugar, un modelo GARCH bien ajustado puede ser robusto en el sentido de aliviar efectivamente los problemas de la no normalidad, la cola gorda y la agrupación de la volatilidad en los datos financieros. Sin embargo, para manejar valores extremos (tail) e implementar correctamente la medición de riesgo, el enfoque EVT debe combinarse con el modelo GARCH para desarrollar un modelo GARCH-EVT más integrado. Por lo tanto, la literatura sugiere la combinación de los enfoques de GARCH y copulación.

En segundo lugar, el enfoque regular de copulación de la vid es útil para captar la estructura de dependencia estática y temporal de las tasas de rendimiento de los activos financieros. Es una herramienta más flexible para modelar casos de alta dependencia dimensional y acomoda diferentes familias paramétricas de copulas. Las funciones de la cúpula son adaptables (cópula elíptica simétrica, cópula asimétrica de Archimedes o cópula mixta), de modo que se pueden analizar datos financieros no normales. Dado que las funciones de copulación son invariantes a transformaciones crecientes y continuas, son útiles en economía y finanzas donde se trabaja frecuentemente con datos transformados.

El investigador concluye que la literatura de investigación recientemente desarrollada proporciona una buena base para el uso de métodos de copulación en la medición del riesgo financiero.

El segundo subobjetivo fue aplicar un enfoque integrado (GARCH-EVT-Copula) para evaluar la estructura de dependencia y explicar las propiedades distributivas de los retornos de los activos financieros en un contexto variable en el tiempo. Para implementar esto, estableció la base empírica para el enfoque integrado. Halló que los datos del mercado financiero coreano tienen una estructura de dependencia que varía en función del tiempo y presenta propiedades procíclicas y anticíclicas en comparación con el momento de varios choques económicos internos y externos. Encontró que la magnitud de la dependencia durante el período está estrechamente relacionada con los shocks basados en una estructura de dependencia variable en el tiempo. Identificó los efectos de diversificación entre los activos financieros y evaluar cómo estos efectos cambian con el tiempo. Compruebo la solidez de estos

efectos explorando alternativas de variación periódica del tiempo de copulación de la vid.

El autor concluye que la mejor adaptación de la copula regular de la vid que varía en el tiempo es útil para analizar la estructura de dependencia variable en el tiempo de los mercados financieros coreanos. La aplicación empírica del modelo GARCH-EVT-Copula a la cartera financiera coreana indica claramente que la estructura de dependencia de los mercados es no lineal, variable en el tiempo y asimétrica. Las estructuras de dependencia que varían en función del tiempo y que se basan en la propiedad de cada activo y dos pares de activos son diferentes en los tres períodos de crisis identificados (la insolvencia crediticia interna, la crisis hipotecaria en Estados Unidos y la crisis fiscal de la UE) proporciona a los inversores ya los responsables de la formulación de políticas información que puede utilizarse para gestionar las consecuencias de estos tipos de crisis económicas en una pequeña economía abierta como Corea.

El tercer subobjetivo era evaluar la coherencia del enfoque integrado. Esto se logró mediante la prueba de nuevo el método de la copulación de la vid periódica variando con el tiempo utilizando las pruebas de excedencia de VaR y ES. A través de las pruebas de retroceso, encuentro que las pruebas de VaR y ES y las pruebas de excedencia confirman que el enfoque del modelo integrado es robusto y consistente en el tiempo. Tanto la estática como las copulas de la vid regulares que se ajustan mejor al tiempo pasan las pruebas de excedencia, pero el enfoque de la variación del tiempo es más preciso con respecto al porcentaje de excedencia. Esto confirma la utilidad de la copula regular de la vid que varía con el tiempo cuando se modelan las no uniformidades y asimetrías que se encuentran en las series de retorno financiero. El retroexamen de estas medidas de riesgo no apoya totalmente la superioridad del modelo de copula de vid regular que varía en el tiempo de GARCH-EVT, pero sí muestra la importancia de las distribuciones marginales correctas al analizar la estructura de dependencia estática y variable en el tiempo de los rendimientos de los activos.

El investigador también concluyó que hay una pequeña diferencia entre el VaR y las pruebas de ES cuando se realizan utilizando la simulación de Monte Carlo. Esto implica que hay más importancia para estimar el modelo GARCH-EVT correctamente, en relación con la selección del modelo de copulación de mejor ajuste. Para mejorar la precisión de las previsiones de riesgo de la cartera, concluyo que los consejos encontrados en Braun & Grizska (2011) son correctos. Hay tres factores que determinan la exactitud de estas previsiones. Estos factores incluyen: la futura estructura de dependencia de los activos, las futuras previsiones de volatilidad univariada y las formas de las distribuciones univariadas. Los dos últimos factores son particularmente útiles para estimar tanto los modelos de cópula estática como los que varían en función del tiempo, porque la estructura de dependencia estática y variable en el tiempo se calcula a partir de los mismos residuos estandarizados de cada activo.

Finalmente, Ortiz (2017), realiza comparaciones entre los modelos GARCH y las redes neuronales diferenciales (RND), para predecir precios de cierre de barriles de petróleo crudo tanto de West Texas International ((WTI) como de Brent, resultando más robustas la predicción con RND. Argumenta que, al analizar series de tiempo, cuyo desenvolvimiento es no lineal, ha sido modelado con la familia de los modelos Garch, debido a que “incorporan las relaciones funcionales que permiten relacionar la volatilidad condicional actual con las volatilidades condicionales pasadas, así como las innovaciones, es posible incluir las variaciones temporales de la volatilidad en los valores de la serie de tiempo analizada”, pero el investigador agrega que actualmente existe un mayor uso de la red neuronal artificial (RNA) para situaciones complicadas, siendo necesario que el periodo de entrenamiento sea prolongado y por encima de 500 datos; posteriormente hacer un etapa de seguimiento para terminar con el pronóstico se series temporales de muy corto plazo. Sin embargo, a partir de los 90 en especial en la etapa meridiana, surge con vigor las redes neuronales artificiales continuas en el tiempo o también conocidas como redes neuronales diferenciales o dinámicas (RND), desplazando a las RNA discretas, a razón de que no utiliza muchas datos en el proceso de entrenamiento y calibración de la red, así como su velocidad de

acoplamiento cuando surgen repentinos cambios de los valores que tome la "serie de tiempo analizada debido a que basa su convergencia en los criterios de estabilidad de Lyapunov". Esta ventaja de las RND permite mayor precisión durante la descripción de las series de tiempo económicas y financieras, cuando tiene un desenvolvimiento no lineal. El periodo de seguimiento de la serie fue desde el "2 de enero de 2013 hasta el 24 de febrero de 2105, y el periodo que corresponde al pronóstico fue del 25 de febrero 2015 al 10 de marzo 2015". Los valores de "ambas series fueron obtenidos de la U.S. Energy Information Administration. dicionalmente, hace una descripción y un pronóstico empleando los modelos de la familia GARCH y muestra los resultados de los valores pronosticados" que fueron calculados con el software E-Views® versión 8. Se compararon los errores cuadráticos medios de las series pronósticadas que se obtuvieron con la RNDA, luego de utilizar varios modelos de la familia Garch, se determinó que el modelo TGARCH(1,1) era el que mejor describía y pronosticaba los valores de la serie del tiempo de precios de cierre de barriles de petróleo crudo del tipo Brent, Con respecto a WTI, los barriles de petróleo tuvieron el cierre de su precio, el mejor modelo encontrado para describir sus valores históricos y realizar pronósticos con menores errores fue el GARCH(1,1). En cambio, TGARCH(1,1) fue contundente frente al modelo RND, al pronosticar el precio de cierre del petróleo crudo Brent, el cual fue comprobado cuando se comparó el "error cuadrático medio (ECM) de ambas series de pronósticos, y cuyos resultados fueren los siguientes: para el modelo TGARCH(1,1), ECM = 0.000729139, y para el modelo con RND, ECM = 0.0008331, obteniéndose una diferencia nimia de 0.000103958". En contraparte, la performance del modelo RND que tuvo un ECM de 0.0004949 fue mejor que el modelo GARCH(1,1) cuando se pronosticaron los precios del crudo WTI, cuyos resultados del ECM fueron 0.002317978, que representa una diferencia de 0.001823078, poco más de 18 diezmilésimos. En conclusión, para pronosticar los precios petróleo crudo Brent, fueron mejores los resultados con TGARCH(1,1) que los calculados con el modelo de RND; empero, ocurre todo lo contrario para los precios de petróleo crudo WTI, en este caso los resultados del modelo RND son más robustos que los obtenidos por medio del modelo TGARCH(1,1). Se evidencia en los casos analizados por el autor que, al pronosticar series de tiempo no

lineales, es más fácil hacerlo a través del modelo de RND fue solo le basta un modelo que pronosticarlo por medio de los modelos de la familia GARCH, pues antes, deberá identificar cual es el más preciso modelo dentro de esta familia. “En el caso de la RND solamente se usó un solo modelo, al cual se alimenta con los valores históricos y se van ajustando sus valores hasta llegar al valor buscado, de acuerdo al criterio de convergencia de Lyapunov”.

2.3 Bases Teóricas

2.3.1 Pronósticos

Los inversionistas individuales, así como las organizaciones buscan estimar el futuro y que estas a su vez, sean lo más certero posible de esta manera planificar sus operaciones, pues son vulnerables del impacto negativo o positivo de las fluctuaciones de las ventas, las variaciones de precio de los insumos y materias primas, el tipo cambio, la tasa de inflación, la volatilidad del precio de las acciones, los resultados económicos financieros, las crisis económicas y financieras y un buen pronóstico puede garantizar la continuidad de sus operaciones en este sistema volátil, competitivo y cambiante. Lo ideal sería un pronóstico a largo plazo, pero esta tiene riesgos siendo lo más recomendable efectuar estimaciones a corto plazo para de esa manera cuantificar los desvíos y efectuar las correcciones necesarias de ser el caso, dependiendo en buena instancia de los umbrales que levanta los mismos inversores.

De Jesús, Vergara y Díaz (2015) cuando se refieren a la necesidad de pronosticar en todo tipo de negocios, estas son de vital importancia en un mercado de constantes cambios y alta volatilidad.

> Pero creemos que el pronosticador eficaz debe ser capaz de establecer una hábil mezcla de pronóstico cuantitativo y buen juicio, evitando los extremos de confiar totalmente en uno o en otro. En un extremo, encontramos al ejecutivo que, por ignorancia y miedo a las computadoras y a las técnicas cuantitativas, confía solamente en su intuición y sensibilidad. En el otro extremo, está el pronosticador diestro en las más avanzadas técnicas actuales de manipulación de datos, pero que parece incapaz o está indispuesto para relacionar el proceso de elaboración del pronóstico, con las necesidades de la organización

> y de sus tomadores de decisiones. Nosotros vemos las técnicas cuantitativas para pronosticar, estudiadas en la mayor parte de este libro, como el único punto de arranque en el pronóstico efectivo de resultados importantes para la organización: análisis, juicio, sentido común y experiencia en el negocio deben aplicarse para brindar apoyo al proceso a través del cual estas importantes técnicas han generado sus resultados (De Jesús, Vergara y Díaz, 2015, p.2).

Por otra parte, Mun (2016) cuando se refiere a pronosticar o predecir el futuro señala que:

> Pronosticar es el acto de predecir el futuro; ya sea en base a en datos históricos o en una simple especulación sobre el futuro, en caso de que los datos no existan. Cuando se cuenta con datos históricos, es recomendable hacer una aproximación estadística o cuantitativa; mientras que, si se carece de estos datos, el único recurso es un juicio de valor o un acercamiento cualitativo (p.429).

Asimismo, el mismo autor para reforzar el entendimiento para pronosticar nos ilustra enumerando las metodologías más populares con la *figura* 2.6:

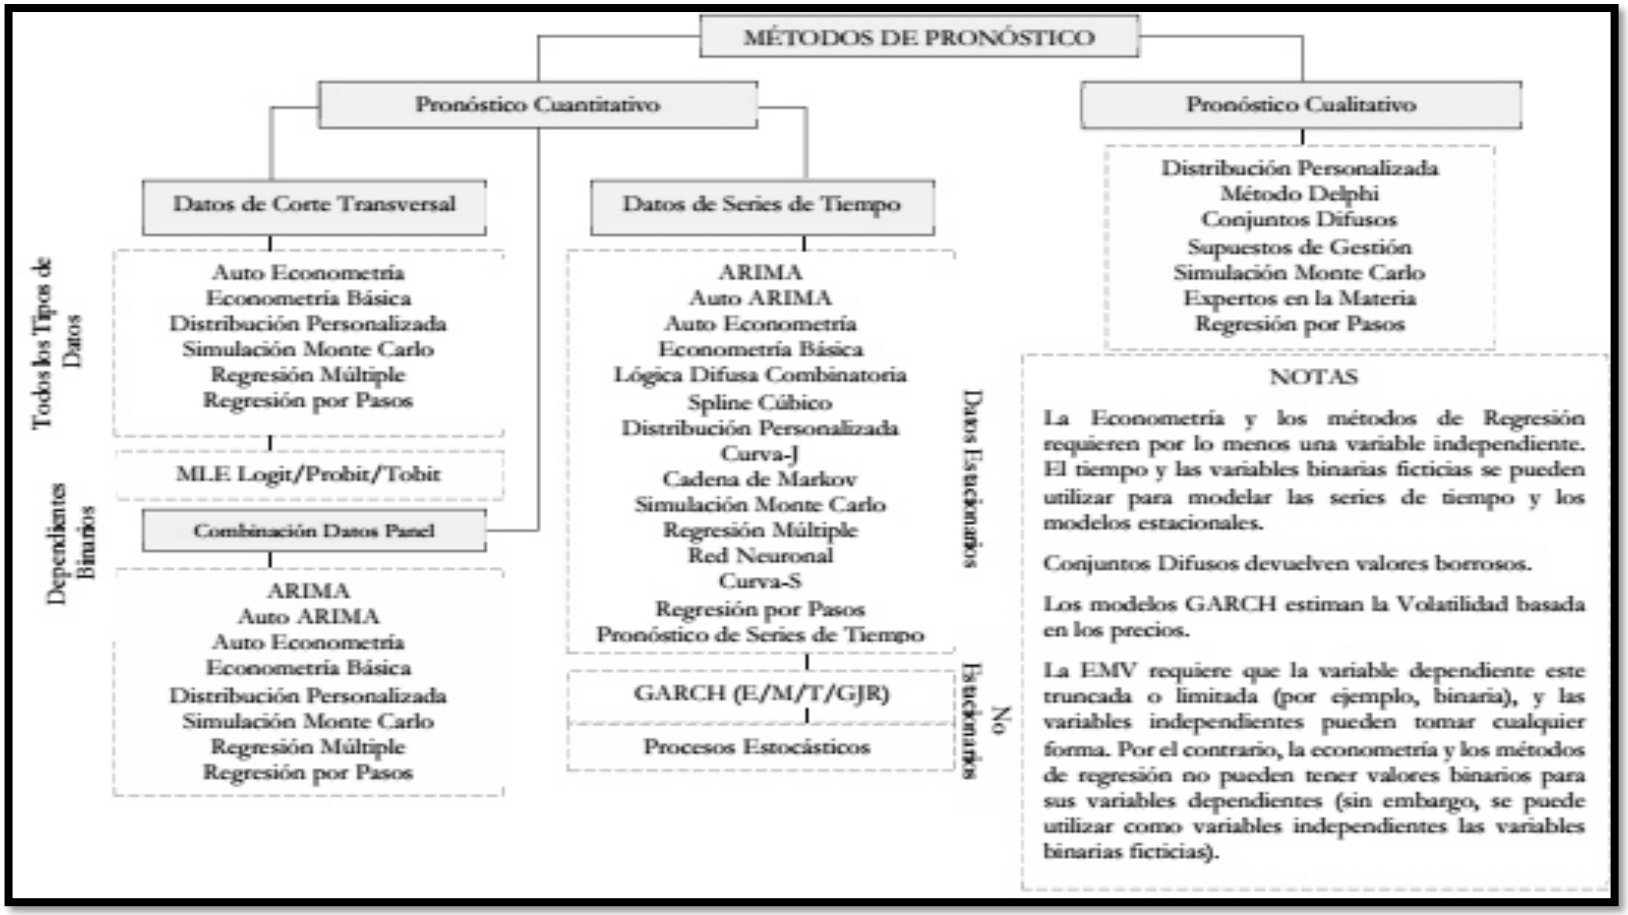

Figura 2.6 Métodos de pronósticos.
Fuente. Mun (2016)

2.3.1.1 Componentes de una serie de tiempo. Newbold, Carlson y Thorne (2008**)** sostienen que los cuatro componentes de las series temporales identificados son los componentes; tendencial, estacional, cíclico e irregular.

- Tendencial: Son movimientos crecientes o decrecientes en un largo plazo.
- Estacional: Son cambios frecuentes que se producen en una línea de tiempo, pero durante un periodo del año
- Cíclico: Se mueven en torno a una tendencia de un extremo a otro y durante un largo tiempo.
- Irregular: Son movimientos imprevisibles influenciados por hechos extraordinarios que producen cambios en una serie temporal.

Hanke y Wichern (2010) dicen que, al analizar datos de series de tiempo, primero debe identificarse los valores de la serie para después descomponer por separado los componentes que la afectan y las proyecciones de estas "se pueden usar luego de manera combinada para elaborar pronósticos de valores futuros de la serie de tiempo. Los métodos de descomposición se usan para pronósticos tanto de corto como de largo plazos". Agregan además los autores que la descomposición, se originan a partir de los cuatro componentes "de las series de tiempo que son la tendencia, cíclico, estacional y el irregular o aleatorio".

2.3.1.2 Promedios móviles. Para minimizar las medidas de precisión al momento de pronosticar Bello (2017) indica dos medidas:

El promedio móvil simple que se utiliza para suavizar una serie temporal corrigiendo sus valores extremos altos poder observan con mayor claridad la tendencia y ciclo. Esto es muy útil para pronosticar pues se tendrá a la mano la información reciente y depurando los datos más antiguos.

$$M_t = Pm_t(K) = \hat{Y}_{t+1} = \frac{Y_t + Y_{t-1} + \cdots Y_{t-k+1}}{K} \quad (1)$$

En cambio, se usan los promedios móviles dobles para pronosticar los datos que tienen una tendencia lineal.

$$\hat{Y}_{t+p} = a_t + b_t p \quad (2)$$

$$a_t = M_t + (M_t - M_t{}') \tag{3}$$

$$M'_t = \frac{M_t + M_{t-1} + \cdots M_{t-k+1}}{K} \tag{4}$$

$$Factor\ de\ ajuste = b_t = \frac{2}{K-1}(M_t - M'_t)$$

Hanke y Wichern (2010) cuando se refieren a “El método de promedios simples esta utiliza la media de todos los datos para hacer el pronóstico”, toma en cuenta un valor constante de datos, al comienzo va calculando la media a medida que aparezcan nuevas observaciones o recientes, calcula la nueva media adicionando el nuevo valor y eliminando el más antiguo, “entonces se usa este promedio móvil para pronosticar el siguiente periodo”. También “Un promedio móvil de orden *k*, MA(*k*)”, es obtenido a través de la ecuación 5.

$$\hat{Y}_{t+1} = \frac{Y_t + Y_{t+1} + \cdots + Y_{t-k+1}}{k} \tag{5}$$

donde

$\hat{Y}_{t+1}$ = valor pronosticado para el siguiente periodo

Y_1 = valor real en el periodo t

k = número de términos en el promedio móvil

Hanke y Wichern (2010) sobre los Promedios móviles dobles dicen que “una manera de pronosticar los datos de las series de tiempo que tienen una tendencia lineal es usar promedios móviles dobles” y procede al calcular un conjunto de promedios móviles en primer término posteriormente procederá a calcular “un segundo conjunto de datos como un promedio móvil del primer conjunto”.

Un promedio móvil doble se construye de acuerdo a las ecuaciones 6 a 10.

Primero, con la ecuación 6 se procederá a calcular el promedio móvil de orden *k*.

$$M_t = \hat{Y}_{t+1} = \frac{Y_t + Y_{t+1} + \cdots + Y_{t-k+1}}{k} \tag{6}$$

Entonces se usa la ecuación 2.7 para calcular el segundo promedio móvil:

$$M'_t = \frac{M_t + M_{t-1} + M_{t-2} + \cdots + M_{t-k+1}}{k} \quad (7)$$

Se utiliza “la ecuación 8 para realizar un pronóstico agregando al promedio móvil simple la diferencia entre el promedio móvil simple y el segundo promedio móvil”.

$$a_t = M_T + (M_T - M'_T) = 2M_T - M'_T \quad (8)$$

La ecuación 9 “es un factor de ajuste adicional, que es similar a la medida de cambio a lo largo de la serie”:

$$b_t = \frac{2}{K-1}(M_t - M'_t) \quad (9)$$

Con la ecuación 10 se pronosticarán los *p* periodos.

$$\hat{Y}_{t+p} = \alpha_t + b_t p \quad (10)$$

donde

k = número de periodos en el promedio móvil
p = número de periodos futuros por pronosticar

2.3.1.3 Métodos de suavizamiento. Mun (2016) afirma “los ocho modelos de series de tiempo más comunes, clasificándolos por estacionalidad y tendencia. Por ejemplo, si la variable de datos no tiene tendencia y estacionalidad, basta con usar un modelo de media móvil simple o un modelo de suavizamiento exponencial simple. Sin embargo, si existe estacionalidad, pero no se percibe la presencia de tendencia, sería mejor usar un modelo estacional aditivo o multiplicativo, y así sucesivamente” (p.485).

Hanke y Wichern (2010) dicen que la suavización exponencial simple a diferencia del método de promedios móviles que prioriza los datos actuales presenta “un promedio móvil con peso exponencial para todos los valores previos observados. A menudo el modelo es adecuado para datos que no tienen una tendencia predecible ascendente o descendente. El objetivo es estimar el nivel real”, pero continuamente revisa los acontecimientos recientes. Este método

suaviza los “datos pasados de una serie de tiempo de forma exponencial decreciente” agregan además que:

> La observación más reciente recibe mayor peso, α (donde 0 < α < 1); la observación anterior recibe menos peso, α (1 - α); la observación dos anteriores recibe menos peso al periodo anterior, α $(1 - \alpha)^2$; y así sucesivamente.
>
> En una representación de suavización exponencial, el nuevo pronóstico (para el tiempo *t* + 1) puede considerarse como la suma ponderada de la nueva observación (en el tiempo *t*) y el antiguo pronóstico (para el tiempo *t*). Se asigna el peso α (0 < α < 1) al nuevo valor observado, y el peso (1 - α) al último pronóstico. Así,
>
> Nuevo pronóstico = [α × (nueva observación)] + [(1 – α) ×- (ultimo observación)]
>
> Más formalmente, la ecuación de suavización exponencial es (Hanke y Wichern, 2010, p.119).

$$\hat{Y}_{t+1} = \alpha Y_t + (1-\alpha)\hat{Y}_t \qquad (11)$$

Donde

$\hat{Y}_{t+1}$ = nuevo valor suavizado o el valor del pronóstico para el siguiente periodo

α = constante de suavización (0<α<1)

Y_1 = nueva observación o el valor real de la serie en el periodo t

$\hat{Y}_1$ = último valor suavizado o en pronóstico del periodo t

La ecuación 12 se puede escribir como:

$$\hat{Y}_{t+1} = \alpha Y_t + (1-\alpha)\hat{Y}_t = \alpha Y_t + \hat{Y}_t - \alpha\hat{Y}_t$$

$$\hat{Y}_{t+1} = \hat{Y}_t + \alpha(Y_t - \hat{Y}_t) \qquad (12)$$

$\hat{Y}_{t+1}$ = nuevo valor suavizado o el valor del pronóstico para el siguiente periodo

α = constante de suavización (0 < α < 1)

Y_t = nueva observación o el valor real de la serie en el periodo *t*

$\hat{Y}_t$ = último valor suavizado o el pronóstico del periodo *t*

La ecuación 2.13 se puede escribir como:

$$\hat{Y}_{t+1} = \alpha Y_t + (1-\alpha)\hat{Y}_t = \alpha Y_t + \hat{Y}_t - \alpha\hat{Y}_t$$
$$\hat{Y}_{t+1} = \hat{Y}_t + \alpha(Y_t - \hat{Y}_t) \qquad (13)$$

De esta manera, el pronóstico actual ($\hat{Y}_{t+1}$) es el anterior ($\hat{Y}_t$) ajustado en α veces el error Y_t - $\hat{Y}_t$ en el pronóstico anterior.

En la ecuación 13, α es "la constante de suavización y actúa como factor de ponderación, su valor determina el grado con el cual la observación reciente impacta en el pronóstico de la siguiente observación". Cuando α se acerca a 1, el pronóstico actual concordará con la observación, pero cuando α es cercano a cero, el nuevo valor pronosticado se asemejará al pronóstico anterior, "y la observación actual tendrá muy poco efecto".

2.3.1.4 Medidas de precisión de pronóstico. Curt y Rengifo (2011) sostienen que "Para determinar si un pronóstico es adecuado, se usan los estadísticos que se presentan a continuación. (…) todos estos estadísticos (…) comparan los valores reales con aquellos que han sido pronosticados. (…) como los errores pueden ser positivos o negativos, (…) suma de ellos no sería de gran ayuda puesto que se cancelarían entre ellos. Es por eso que los índices trabajan ya sea con los errores al cuadrado o con el valor absoluto de los errores" (pp.427-428), pasando a indicar las medidas de precisión:

- La media de los errores al cuadrado (Mean Square Error - MSE), definida como:

$$MSE = \sum_{j=t+r}^{t+r} \left(y_j - g_{t,j}\right)^2 \qquad (14)$$

- La media absoluta de los errores (Mean Absolute Error - MAE) definida como:

$$MAE = \frac{\sum_{j=t+r}^{t+r} \left|y_j - g_{t,j}\right|}{r} \qquad (15)$$

- La media absoluta de errores porcentuales (Mean Absolute Percentage Error - MAPE) definida como:

$$MAPE = \frac{\sum_{j=t+r}^{t+r} \left| \frac{y_j - g_{t,j}}{g_{t,j}} \right|}{r} x100 \qquad (16)$$

- El coeficiente de desigualdad de Theil (Theil Inequality Coefficient) definida como:

$$Theil = \sqrt{\sum_{j=t+r}^{t+r} \frac{\left(\frac{y_j - g_{t,j}}{y_j}\right)^2}{\left(\frac{y_j - g^b{}_{t,j}}{y_j}\right)^2}} \qquad (17)$$

2.3.2 Las series de tiempo

Ramón y López (2016) definen las series de tiempo como "Una serie temporal o cronológica es una secuencia de datos, observaciones o valores, medidos en determinados momentos del tiempo, ordenados cronológicamente y, normalmente, espaciados entre sí de manera uniforme. El análisis de series temporales comprende métodos que ayudan a interpretar este tipo de datos, extrayendo información representativa, tanto referente a los orígenes o relaciones subyacentes como a la posibilidad de extrapolar y predecir su comportamiento futuro. Tanto en economía de empresa como en el campo de la macroeconomía se plantea continuamente el problema de la toma de decisiones, es decir, la elección de una opción entre diversas alternativas en un ambiente de incertidumbre. El decisor podrá obtener unos mejores resultados si, en alguna medida, logra reducir la incertidumbre sobre los sucesos situados en el futuro. A reducir la incertidumbre sobre el futuro van dirigidas las técnicas de predicción, y el análisis de series temporales, en particular"

2.3.2.1 Procesos estocásticos y estacionariedad. Se describe al proceso estocástico como:

> Un concepto clave en los modelos de series de tiempo es el conocido como procesos estocásticos. Un proceso estocástico es una secuencia de números aleatorios. El proceso estocástico se escribirá como { yi } para i = 1, 2,… Si este índice representa tiempo, el proceso estocástico se

llamará serie de tiempo. Si se asigna un posible valor de y por cada i se estará construyendo una posible realización del proceso estocástico. (Court y Rengifo, 2011, p.400).

Asimismo, Court y Rengifo (2011) con respecto a la estacionaridad sostienen “las observaciones de las series de tiempo provienen de la misma distribución de probabilidad y que, si a su vez el proceso no es muy persistente, cada observación contendrá información valorable que no está presente en ninguna de las otras observaciones” (p,400).

Ramón y López (2016) dicen que un “proceso estocástico es un concepto matemático que sirve para caracterizar una sucesión de variables aleatorias (Y_t) que evolucionan en función de otra variable, generalmente el tiempo”, cada variable aleatoria tiene su propia distribución de probabilidad que a su vez pueden estar correlacionadas o no.

Cada una de las variables Y_t que configuran un proceso estocástico tendrá su propia función de distribución con sus correspondientes momentos. Asimismo, cada conjunto de variables tendrá su correspondiente función de distribución conjunta y sus funciones de distribución marginales. Habitualmente, conocer esas funciones de distribución resulta complejo de forma que, para caracterizar un proceso estocástico, basta con especificar la media y la varianza para cada y_t y la covarianza para variables referidas a distintos valores de t (Ramón y López,2016, p.63).:

$$\mu_t = E(y_t) \tag{18}$$

$$\Upsilon_0 = Var(y_t) = E[(y_t - \mu_t)^2] \tag{19}$$

$$\gamma_{t,s} = Cov(y_t, y_s) = E[(y_t - \mu_t)(y_s - \mu_s)] \tag{20}$$

2.3.2.2 Identificación de la estacionariedad. Court y Rengifo (2011) señalan que “El concepto de estacionariedad tiene dos versiones: la estacionariedad estricta y la estacionariedad débil” (p.400) para lo cual se pasan a mostrar cada una de estas, de acuerdo a los mismos autores

- Estacionariedad estricta. - “Es un proceso estocástico { yi } con i = 1, 2,…T es estrictamente estacionario si, para un número real finito r y para cualquier conjunto de subíndices i1 , i2 ,…, iT”: (p.400), que se define de esta forma:

$$\boldsymbol{F_{yi_1.yi_2....yi_T}(y_1, \dots, y_T) = F_{yi_{1+r}.yi_{2+r}....yi_T+r}(y_1, \dots, y_T)} \qquad (21)$$

- Estacionariedad débil. – Court y Rengifo (2011) dicen que “Es un proceso estocástico { yi } con i = 1, 2,…T es débilmente estacionario si se cumple lo siguiente”:

$$E(y_i) = \mu$$

$$E(y_i - \mu)^2 = \sigma^2 < \infty$$

$$cov(y_i . y_{i-j}) = y_{i-(i-j)} = y_j$$

Ramón y López (2016) identifican la estacionariedad de la siguiente manera:

- **Proceso estocástico estacionario en sentido fuerte.** Decimos que un proceso estocástico es estacionario en sentido estricto o fuerte si las funciones de distribución conjuntas (no sólo la esperanza, las varianzas o las covarianzas, sino las funciones de distribución “completas”) son constantes, o dicho con más propiedad, son “invariantes con respecto a un desplazamiento en el tiempo” (variación de t). Es decir, considerando que t, t+1, t+2, ..., t+k, reflejan períodos sucesivos:

$$\boldsymbol{F(Y_t, Y_{t+1} \dots, Y_{t+k}) = F(Y_{t+m}, Y_{t+1+m} \dots, Y_{t+k+m})} \qquad (22)$$

para cualquier t, k y m (Ramón y López,2016, p.63).

- **Proceso estocástico estacionario en sentido débil:** La definición de estacionariedad en sentido estricto puede relajarse sustancialmente utilizando la denominada estacionariedad en sentido amplio o débil.

Ramón y López,2016 sostienen que “Las esperanzas matemáticas de las variables aleatorias no dependen del tiempo, es decir, son constantes”. A continuación, se presenta la ecuación:

$$E(Y_t) = E(Y_{t+m})\ \forall m \tag{23}$$

- Las varianzas tampoco dependen del tiempo (y son finitas):

$$Var(Y_t) = Var(Y_{t+m}) < \infty\ \forall m \tag{24}$$

Ramón y López,2016 agregan que “Las covarianzas entre dos variables aleatorias del proceso correspondientes a períodos distintos de tiempo (distintos valores de t) sólo dependen del lapso de tiempo transcurrido entre ellas” y tiene la siguiente notación:

$$Cov(Y_t, Y_s) = Cov(Y_{t+m}, Y_{s+m})\ \forall\ m \tag{25}$$

Larios, Álvarez y González (2016) dicen que cuando se verifica la existencia de estacionariedad de las series de tiempo de importantes variables económicas y financieras de uso frecuente en el Perú, tales como el índice general de la Bolsa de Valores, renta de factores, términos de intercambio y consumo privado.

Sin esta propiedad, el trabajo de predicción es inútil porque sus resultados pierden credibilidad (son espurios). Las series son sometidas a esta verificación mediante correlogramas y la prueba de raíz unitaria de Dickey-Fuller Aumentado. Para llevar a cabo esta tarea, los datos de las series son ajustados a modelos autorregresivos (AR), de media móvil (MA) y de caminata aleatoria o Random Walk, con el propósito de simular, por ejemplo, condiciones de no estacionariedad que luego son confirmadas por los distintos indicadores obtenidos en esta evaluación. Finalmente, en caso de encontrar series no estacionarias, se propone eliminar esta condición con procesos de diferenciación.

2.3.2.3. Pruebas de raíz unitaria. Court y Rengifo (2011) mencionan que “la condición fundamental para el uso de estos modelos de serie de tiempo es el proceso estocástico (la serie de tiempo) { y_t } que sea estacionaria o, en términos financieros, se debe estar seguro que la serie revierte a su media y que no se trata de un proceso con raíz unitaria o explosiva” (p.413).

Por otra parte, Wooldridge (2010) sostiene que “Una caminata aleatoria es un caso especial de lo que se conoce como proceso de raíz unitaria. (…) que $\rho_1 = 1$” (p.391).

Gujarati y Porter (2010) dicen “Otra prueba sobre estacionariedad (o no estacionariedad) que se populariza cada vez más se conoce como **prueba de raíz unitaria**. Primero la explicaremos, luego la ilustraremos y después consideraremos algunas limitantes de esta prueba.

El punto de partida es el proceso (estocástico) de raíz unitaria (…), se inicia con

$$Y_t = \rho Y_{t-1} + u_t \qquad -1 \leq \rho \leq 1 \tag{26}$$

donde u_t es un término de error de ruido blanco.

Sabemos que si ρ = 1, es decir, en el caso de la raíz unitaria, (26) se convierte en un modelo de caminata aleatoria sin deriva, del cual sabemos también que es un proceso estocástico no estacionario. Por consiguiente, ¿por qué no simplemente hacer la regresión de Y_t sobre su valor rezagado (de un periodo) Y_{t-1} y se averigua si la ρ estimada es estadísticamente igual a 1? De ser así, Y_t es no estacionaria. Ésta es la idea general de la prueba de raíz unitaria para la estacionariedad.

Sin embargo, no podemos estimar la ecuación (26) por MCO y probar la hipótesis de que ρ = 1 por medio de la prueba t acostumbrada, porque esa prueba tiene un sesgo muy marcado en el caso de una raíz unitaria. Por tanto, manipulamos (26) de la siguiente forma: restamos Y_{t-1} de ambos miembros de la ecuación 26 para obtener: $= \hat{\delta}$

$$\begin{aligned} Y_t - Y_{t-1} &= \rho Y_{t-1} - Y_{t-1} + u_t \\ &= (\rho - 1)\, Y_{t-1} + u_t \end{aligned} \tag{27}$$

la cual también se expresa como:

$$\Delta Y_t = \delta Y_{t-1} + u_t \tag{28}$$

donde δ = (ρ − 1) y Δ, como siempre, es el operador de primeras diferencias.

Por tanto, en la práctica, en vez de estimar (26), calculamos (28) y probamos la hipótesis (nula) de que δ = 0, y la hipótesis alternativa es que δ < 0 (nota 1). Si δ = 0, entonces ρ = 1; es decir, tenemos una raíz unitaria, lo cual significa que la serie de tiempo en consideración es no estacionaria.

Antes de proceder con la estimación de (28) debemos observar que si δ = 0, entonces (28) se convertirá en

$$\Delta Y_t = (Y_t - Y_{t-1}) = u_t \qquad (29)$$

Como u_t es un término de error de ruido blanco, entonces es estacionario, lo cual significa que las primeras diferencias de una serie de tiempo de caminata aleatoria son estacionarias, una observación que ya habíamos hecho.

Ahora reconsideremos la estimación de (28). Esto es muy simple: sólo hay que tomar las primeras diferencias de Y_t y hacer la regresión sobre Y_{t-1}, a fin de ver si el coeficiente estimado de la pendiente en esta regresión es o no cero. Si es cero, concluimos que Y_t es no estacionaria; pero si es negativa, $(= \hat{\delta})$ se infiere que Y_t es estacionaria. La única interrogante es saber con qué prueba averiguar si el coeficiente estimado de Y_{t-1} en (28) es o no cero. Uno estaría tentado a utilizar la prueba t usual. Por desgracia, según la hipótesis nula de que δ = 0 (es decir, ρ = 1), el valor t del coeficiente estimado de Y_{t-1} no sigue la distribución t ni siquiera en muestras grandes, es decir, no tiene una distribución normal asintótica.

Para conocer la alternativa, Dickey y Fuller probaron que según la hipótesis nula de que $\delta = 0$, el valor estimado t del coeficiente Y_{t-1} en (28) sigue el **estadístico *τ* (tau)**. Estos autores calcularon los valores críticos del *estadístico tau* con base en simulaciones Monte Carlo. En la bibliografía, el **estadístico** o **prueba tau** se conoce como **prueba Dickey-Fuller (DF)**, en honor a sus descubridores. Resulta interesante que si rechazamos la hipótesis de que $\delta = 0$ (es decir, la serie de tiempo es estacionaria), podemos utilizar la prueba t (de Student) usual. Se deberá tener en cuenta que la prueba Dickey-Fuller es unidireccional porque la hipótesis alternativa es que $\delta < 0$ (o $\rho < 1$).

El procedimiento real para aplicar la prueba DF supone diversas decisiones. Al analizar la naturaleza del proceso de raíz unitaria (…) observamos que un proceso de caminata aleatoria tal vez no tiene deriva, o quizá sí, o posiblemente tiene tendencia determinista y estocástica. A fin de permitir las distintas posibilidades, la prueba DF se estima en tres diferentes formas, es decir, conforme a tres hipótesis nulas:

Y_t es una caminata aleatoria:	$\Delta Y_t = \delta Y_{t-1} + \mu_t$	(30)
Y_t es una caminata aleatoria con deriva:	$\Delta Y_t = \beta_1 + \delta Y_{t-1} + \mu_t$	(31)
Y_t es una caminata aleatoria con deriva alrededor de una tendencia determinista:	$\Delta Y_t = \beta_1 + \beta_2 t + \delta Y_{t-1} + \mu_t$	(32)

donde *t* es la variable de tiempo o de tendencia. En cada caso, las hipótesis son:

Hipótesis nula: H_0:$\delta = 0$ (es decir, existe una raíz unitaria, la serie de tiempo es no estacionaria o tiene tendencia estocástica).

Hipótesis alternativa: H_1:$\delta < 0$ (es decir, la serie de tiempo es estacionaria, posiblemente alrededor de una tendencia determinista).

Si rechazamos la hipótesis nula, esto significa que 1) Y_t es estacionaria con media cero en el caso de la ecuación 30 o que 2) Y_t es estacionaria con una media distinta de cero en el caso de 31. En el caso de la ecuación 32, podemos probar que $\delta < 0$ (es decir, no hay tendencia estocástica) y $\alpha \neq 0$ (es decir, la existencia de una tendencia determinista) simultáneamente, mediante la prueba *F* pero con los valores críticos tabulados por Dickey y Fuller. Cabe señalar que una serie de tiempo puede contener tanto una tendencia estocástica como una determinista”

2.3.3 Regresión con variables de serie de tiempo

2.3.3.1 Regresión espuria. Wooldridge (2010) expresa que

En un entorno de corte transversal, se utiliza la frase “correlación espuria” para describir una situación en la que dos variables están relacionadas a través

de su correlación con una tercera variable, (…) esto también puede suceder en contextos de series de tiempo. (…) es posible encontrar una relación espuria entre series de tiempo que tienen tendencias" (Wooldridge, 2010, p.636).

Gujarati y Porter (2010), agregan "Para ver por qué las series de tiempo estacionarias son tan importantes, considere los dos modelos de caminata aleatoria siguientes":

$$Y_t = Y_{t-1} + u_t \tag{33}$$

$$X_t = X_{t-1} + v_t \tag{34}$$

donde se generaron 500 observaciones de u_t a partir de $u_t \sim N(0, 1)$ y 500 observaciones de v_t a partir de $v_t \sim N(0, 1)$, además de que se supuso que los valores iniciales de Y y X eran cero. También se supuso que u_t y v_t no están serial ni mutuamente correlacionadas. Como ya sabemos, ambas series de tiempo son no estacionarias; es decir, son I(1) o exhiben tendencias estocásticas (Gujarati y Porter, 2010, p. 747).

Que los resultados de la regresión presentados antes carezcan de sentido se advierte con facilidad al hacer la regresión de las primeras diferencias de Y_t (= ΔY_t) sobre las primeras diferencias de X_t (=ΔX_t); recuerde que aunque Y_t y X_t son no estacionarias, sus primeras diferencias sí lo son. En esta regresión veremos que R^2 es prácticamente cero, como debe ser, y que la *d* de Durbin-Watson es de casi 2 (Gujarati y Porter, 2010, p. 748).

2.3.3.2 Cointegración. Engle y Granger (como se citó en Wooldridge, 2010) dieron un tratamiento formal a la cointegración haciendo potencialmente significativa las regresiones que implican variables I(1) (…) Si $\{y_t: t = 0, 1,\ldots\}$ y $\{x_t: t = 0, 1,\ldots\}$ son dos procesos I(1), entonces (…) $y_t - \beta x_t$ es un proceso I(1) para cualquier número β. Sin embargo, es posible que para algunas $\beta \neq 0$, $y_t - \beta x_t$ "sea un proceso I(0), lo cual significa que tiene media constante, varianza constante y las autocorrelaciones que dependen sólo del periodo transcurrido entre dos variables cualesquiera en la serie y no está correlacionada asintóticamente".

Court y Rengifo (2011), dicen que las series de tiempo no estacionarias pueden cointegrarse debido a la relación existente de las variables en el largo plazo es decir “que existe alguna fuerza que hace que las variables tiendan a un equilibrio o a un estado estacionario en el largo plazo”. Para convertir una serie que no estacionaria en estacionaria, es necesario diferenciar sus series, pero si se desea volver al estado original, se deberá integrar entonces “a la serie original (no estacionaria) se le conoce como una serie integrada de grado d. El grado se refiere al número de veces que hay que integrar la serie diferenciada hasta obtener la serie original” y se expresa de la siguiente forma:

$$y_t \sim I(d) \tag{35}$$

Es decir, que la variable y_t es una serie no estacionaria estocástica integrada de orden d (se necesitará diferenciarla d veces para obtener una serie estacionaria), será necesario diferenciar una serie no estacionaria más de una vez. En finanza, en la mayoría de las situaciones bastará con una solo diferencia para lograr la estacionariedad. Si se acepta que este es el caso, se definirá a una serie integrada de grado uno como:

$$y_t \sim I(d) \tag{36}$$

Ahora, se pasa a definir cointegración asumiendo que todas nuestras series son integradas de orden 1.

Al existir k series, cada una con solo una diferencia I(1), se podrá afirmar de que habrá una relación de cointegración, si existe una combinación lineal que hace que estas sean integradas de orden cero, I(0); se dice que habrá un vector de cointegración y por tanto, el resultado de la serie sea estacionaria o I(0). Matemáticamente,

$$\sum_{i}^{k} \delta_i \text{ x } y_i \sim I(0) \tag{37}$$

Gujarati y Porter (2010) cuando se refieren a la cointegración, sostienen que la regresión espuria ocurre cuando la regresión de una serie temporal con referencia a otra u otras variables presenta resultados ilógicos, pero con la

cointegración se evade esta anomalía a través de una combinación lineal que podría ser estacionaria a pesar de que individualmente la serie de tiempo no sea estacionaria. “La cointegración de dos (o más) series de tiempo indica que existe una relación de largo plazo, o de equilibrio, entre ellas”.

10. El **mecanismo de corrección de errores (MCE)** de Engle y Granger sirve para conciliar el comportamiento de corto plazo de una variable económica con su comportamiento de largo plazo.

11. El campo de la econometría de series de tiempo ha evolucionado. Los resultados y pruebas establecidas en algunos casos son tentativos y queda aún mucho trabajo pendiente. Una pregunta importante, aún pendiente, es por qué algunas series de tiempo económicas son estacionarias y otras no lo son (Gujarati y Porter, 2010, p. 769).

2.3.3.3 Modelos de corrección de errores. Court y Rengifo (2011) sostienen que “Si las series son cointegradas se puede utilizar el modelo de corrección de errores. (…), el modelo de corrección de errores toma la siguiente forma:

$$\Delta y_t = \alpha + \beta_1 x\, \Delta X_{1,t} + \beta_2 x\, \Delta X_{2,t} + \beta_3 x\, \left(y_{t-1} - \gamma, -\delta_1 x X_{1,t-1}, -\delta_2\, x\, X_{2,t-1}\right) \quad (38)$$

En este caso, si existe un vector de cointegración $(1, -\gamma, -\delta_1, -\delta_2)$ implicará que el termino entre paréntesis es estacionario y, por lo tanto, la ecuación puede ser adecuadamente estimada y, también, será posible realizar inferencia sobre los coeficientes estimados” (Pp.528, 529).

Gujarati y Porter (2010) agregan lo siguiente: “Acabamos de demostrar que, teniendo en cuenta la tendencia (lineal), LGCP y LIPD están cointegradas, es decir, hay una relación de equilibrio de largo plazo entre las dos. Desde luego, en el corto plazo puede haber desequilibrio”, por consiguiente, con la ecuación adjunta, se asume el “termino de error y así relacionar el desenvolvimiento a corto plazo del GCP con su valor de largo plazo:”

$$\mu_t = \mathrm{LGCP}_t - \beta_1 - \beta_2 \mathrm{LIPD} - \beta_3 t \quad (39)$$

2.3.4 Modelos univariados de series de tiempo

2.3.4.1 Metodología Box-Jenkins y los modelos ARIMA. Está metodología fue formalizada por Box y Jenkins en 1976, y como resultado de esto se le conoce también como modelos Box-Jenkins, tiene su punto de partido en que las series temporal que intentan pronosticar tiene como punto de apoyo a los procesos estocásticos caracterizadas a través de un modelo. Al intentar pronosticar por medio de un modelo ARIMA (Modelos Autorregresivos Integrados de Medias Móviles) que según Meléndez (2017) estos modelos "de la metodología Box-Jenkins siguen los siguientes pasos a través de escenarios de ensayo y error:

0. Evaluación de la estacionariedad
1. Identificación
2. Estimación
3. Validación
4. Pronóstico".

En Box, Jenkins y Reinsel (2008) se puede encontrar graficar dichos pasos y que los autores lo denominan como "Etapas en el enfoque iterativo de la construcción de modelos" (p.18) y que es ilustrada con la *figura* 2.7:

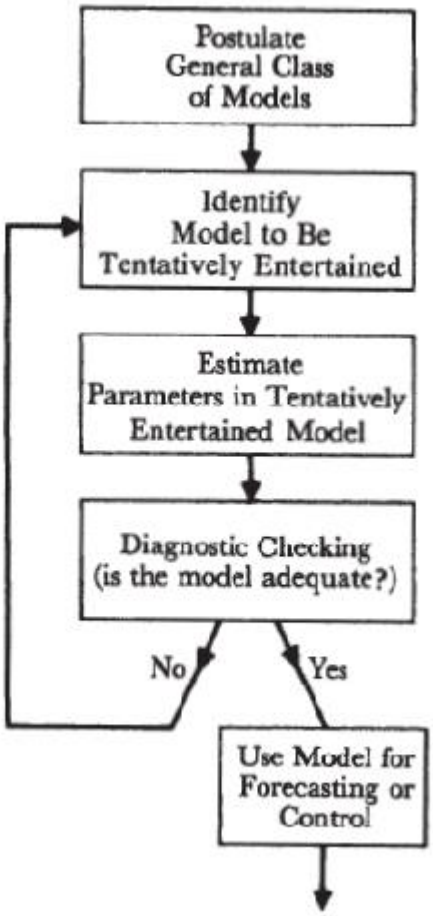

Figura 2.7 Etapas de la construcción del modelo de Box y Jenkins
Fuente. Box, Jenkins y Reinsel (2008)

Sobre La metodología de Box-Jenkins, Court y Rengifo (2011) escriben que fue desarrollada por Box & Jenkins y que necesariamente contiene los siguientes pasos:

- Determinar el modelo y el orden de los mismos que mejor se ajusta a los datos. Para ello se utilizan los métodos gráficos y los criterios de información presentados anteriormente.
- Estimar el modelo seleccionado, es decir, estimar los coeficientes del modelo seleccionado en el paso anterior.
- Verificar si el modelo seleccionado en el paso anterior es adecuado. Para esto existen dos métodos: el primero consiste en crear un modelo con más rezagos que los identificados en el paso previo y verificar que los rezagos extra no son estadísticamente significativos. El segundo método consiste en analizar los residuos del modelo seleccionado. Si el modelo seleccionado captura adecuadamente la dinámica de la variable, los errores deberían ser ruidos blancos, es decir deberían ser no

autocorrelacionados. Esto se puede probar mediante la prueba de Ljung-Box.

• Realizar inferencias y pronósticos con el modelo estimado (Court y Rengifo, 2011, p.430).

2.2.4.2 Modelos de medición de volatilidad. Gujarati y Porter (2010) mencionan que las series temporales de tipo financiero, tienen mucha acumulación de volatilidad con altas variaciones durante periodos prolongados y posteriormente, periodos prolongados de baja volatilidad o de relativa calma, agregan además que estas series financieras en niveles o precios originales tienen la característica de presentar caminatas aleatorias o ser no estacionarias. En la mayoría de las ocasiones, es suficiente para que una serie se convierta en estacionaria, pero estas diferencias presentan altas volatilidades que indica que la varianza es heterocedástica

Lo cual indica que la varianza de las series de tiempo financieras se modifica con el tiempo, entonces deberá modelarse con el modelo de **heteroscedasticidad condicional autorregresivo** (ARCH), que originalmente lo desarrolló Engle. y argumentan Como su nombre lo indica, la heteroscedasticidad, o varianza desigual, puede tener una estructura autorregresiva en la que la heteroscedasticidad observada a lo largo de diferentes periodos quizá esté autocorrelacionada. También hacen la notación "Desde su "descubrimiento", en 1982, la elaboración de modelos ARCH se ha convertido en un área floreciente, con todo tipo de variantes respecto del modelo original. Uno muy popular es el **condicional autorregresivo generalizado con heteroscedasticidad**, propuesto por Bollerslev. El modelo GARCH más simple es el GARCH(1,1)" (Gujarati y Porter, 2010, p.791), cuya notación se expresa como:

$$\sigma_t^2 = \alpha_0 + \alpha_1 u_{t-1}^2 + \alpha_2 \sigma_{t-1}^2 \qquad (40)$$

Por otra parte, en Court y Rengifo (2011) se encontró el modelo ARCH (Autoregressive Conditional Heteroskedasticity), de bastante uso en finanzas por su fortaleza para hacer pronósticos dado su robustez estadística. Los autores afirman que

El modelo fundamental que originó una serie de nuevos modelos es el conocido como el modelo ARCH(q) y fue desarrollado por el premio Nobel de Economía 2003, Robert Fry Engle en el año 1982 (…) que los modelos desarrollados a partir de este modelo son de bastante uso en las finanzas y que busca pronosticar el rendimiento y la volatilidad esperados de los instrumentos financieros y en términos econométricos modelar la media y la varianza condicional de una serie de tiempo de manera simultánea. Entendiéndose la volatilidad como un concepto crucial en finanzas ya que mide la dispersión de los datos alrededor de alguna medida de tendencia central como la media (Court y Rengifo, 2011, p.452).

El modelo ARCH, captura Los retornos que tienden a agruparse durante periodos de alta volatilidad y baja volatilidad, sin embargo, el número de rezagos (q) requeridos puede ser demasiado grande debido a la no parsimonia del modelo y que se viola la condición de no negatividad trayendo como consecuencia varianzas condicionales negativas. Adicionalmente, no se sabe cuál podría ser el numero adecuado de rezagos requeridos y por tal razón "lo mejor (…) es utilizar un modelo que es la generalización del modelo ARCH original y que de manera bastante sencilla solucione los problemas mencionados. Ese modelo es conocido como el modelo ARCH generalizado, GARCH(p,q). El modelo GARCH(p,q)" (p.458). Es expresa con la esta ecuación:

$$\begin{cases} u_t = z_t x \sigma_t \\ z_t \sim i.i.d.D(0,1) \\ \sigma_t^2 = \omega + \sum_{i=1}^{q} \alpha_i \, x u_{t-1}^2 + \sum_{j=1}^{p} \beta_j \, x \sigma_{t-j}^2 \end{cases} \tag{41}$$

A continuación, se presentan los diferentes tipos de Modelos de medición de volatilidad:

2.3.4.3 Modelos de medición de volatilidad: ARCH. Encontramos que Bello (como se citó en Engle, 1982) cuando se refiere a los modelos ARCH (Autoregressive conditional heteroskedasticity) que se introduce una nueva clase de procesos estocásticos, por lo cual la varianza condicionada a la información pasada no es constante y depende del cuadrado de las innovaciones pasadas y que están representadas por la siguiente notación:

$$Y_t = \beta_0 + e_t$$

$$Donde: e_t \sim N(0, \sigma_t^2)$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \alpha_2 \varepsilon_{t-2}^2 + \cdots + \alpha_p \varepsilon_{t-q}^2$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^{q} \alpha_1 \varepsilon_{t-1}^2$$

$$ARCH(1): \sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 \qquad \alpha_0 > 0, \qquad 0 < \alpha_1 < 1$$

Asimismo, el autor plantea las siguientes observaciones de los modelos ARCH:

- El primer parámetro indica la mínima varianza condicional.
- El segundo parámetro verifica la persistencia de la volatilidad y de acercarse a la unidad, indica una alta persistencia de los choques de volatilidad
- El modelo asume que tanto las noticias buenas y malas tienen el mismo impacto sobre la volatilidad, pues dependen de las perturbaciones al cuadrado rezagadas (q) periodos lo que significa que el precio de un activo financiero responde indistintamente ante buenas y malas noticias.
- Los modelos ARCH posiblemente sobre predicen la volatilidad debido a respuesta retardada ante los valores extremos de la serie de retornos.

El mismo autor con respecto a los modelos ARCH plantea pruebas de Hipótesis para detectar el efecto ARCH.

Court y Rengifo (2011) sostienen que 1982, Robert Fry Engle a la postre premio Nobel de Economía en el 2003, desarrolló el modelo inicial ARCH(q) y que, a partir de este, surgen otros modelos que son muy utilizadas en finanzas pues ayudan a pronosticar rendimientos y volatilidades esperados de instrumentos financieros. Además, al mismo tiempo modela la media y la varianza condicional de una serie temporal controlando los errores o perturbaciones. La media condicional puede ser representada a través de una ecuación de modelos de la forma de mínimos cuadrados ordinarios o de series

de tiempo. En el caso de la media condicional puede ser expresada de la siguiente manera:

$$y_t = \alpha + \beta_1 x\, X_{1,t} + \beta_2 x\, X_{2,t} + u_t \qquad (42)$$

Se asume que la media condicional es convenientemente modelada por un modelo AR(1) que tomará la siguiente expresión:

$$y_t = \mu + \emptyset_1 x\, y_{t-1} + u_t \qquad (43)$$

En la que: $\boldsymbol{u_t}$ expresa los errores del modelo.

El modelo ARCH(q)

Si se parte "del modelo de la media condicional presentado en la ecuación 43, se define el modelo ARCH(q) a partir de los errores ($\boldsymbol{u_t}$) presentados en la ecuación" 44:

$$\begin{cases} u_t = z_t x \sigma_t \\ z_t \sim i.i.d.\, D(0,1) \\ \sigma_t^2 = \omega + \sum_{i=1}^{q} \alpha_i\, x u_{t-1}^2 \end{cases} \qquad (44)$$

Se procedió con descomponer el error en dos partes: $\boldsymbol{z_t}$ que se conoce como el error estandarizado y $\boldsymbol{\sigma^t}_2$ que es la varianza condicional de los errores. "se supone que z_t se distribuye como D(.), es decir, que D(.) representa una densidad de probabilidad. Las distribuciones de densidad de probabilidad más usadas son la normal, la t de Student y la distribución generalizada de los errores".

Teniendo como punto de partida la ecuación (44), se precisa el modelo ARCH(2), suponiendo que $\boldsymbol{z_t}$ tiene una distribución normal estándar, con esta ecuación:

$$\begin{cases} u_t = z_t x \sigma_t \\ z_t \sim i.i.d.D(0,1) \\ \sigma_t^2 = \omega + \alpha_1 \, x \; u_{t-1}^2 + \alpha_2 \, x \; u_{t-2}^2 \end{cases} \quad (45)$$

El modelo ARCH tiene la capacidad de capturar el agrupamiento de las volatilidades cuando se presentan noticias negativas.

Los movimientos de volatilidad agrupados se observan frecuentemente en las series de los retornos de las acciones cotizadas en bolsa de valores. Estos movimientos se deben a que grandes cambios en los precios de las acciones tienden a ser seguidas de grandes cambios, de cualquier signo, y pequeños cambios son seguidos de pequeños cambios. Este movimiento en los retornos a su vez genera similar comportamiento en la volatilidad del instrumento financiero. Es decir que, grandes cambios de volatilidad tienden a seguir grandes cambios mientras que pequeños cambios de volatilidad tienden a seguir pequeños cambios. Este comportamiento es el que se puede observar en la figura 2.8, que presenta los retornos de S&P 500 desde enero de 1990 hasta el 26 de febrero 2010 (Court y Rengifo, 2011, pp. 453-454).

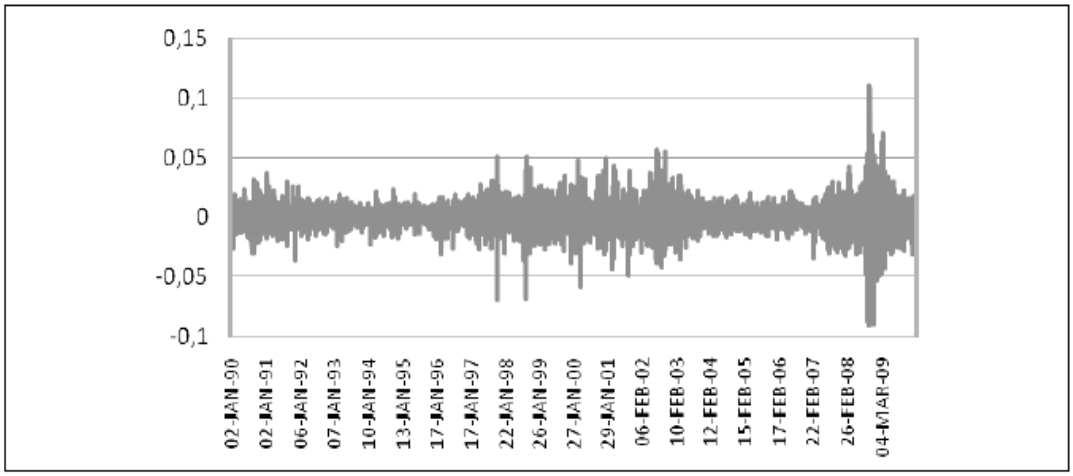

Figura 2.8 Modelos de heteroscedasticidad condicional autorregresiva
Fuente. Court y Rengifo (2011)

Se observar en la figura 2.8, que durante el periodo 2008 al 2009 hubo alta volatilidad y los retornos se agruparon, pero el periodo 2005 al 2006 que fue de relativa cama o baja volatilidad también los retornos se agruparon. El modelo ARCH toma en cuenta estos agrupamientos de las volatilidades y se advierte en

la parte final de la ecuación (44) que "la volatilidad condicional es una función de los errores al cuadrado. Por lo tanto, si u_{t-1} fue grande en términos absolutos, se espera que las siguientes varianzas condicionales sean también grandes". Pero, si u_{t-1} fue pequeña, en el periodo t, $t + 1$, etc. también será pequeña.

2.3.4.4 Modelos de medición de volatilidad: GARCH. Bollerslev (1986), propuso el modelo GARCH (Generalized AutoRegressive Conditional Heteroskedasticity) como un desarrollo a los modelos ARCH. En este caso la varianza condicional no solo depende de las perturbaciones sino también de las varianzas condicionadas por el pasado.

$$\sigma_t^2 = \alpha_0 + \alpha_1\varepsilon_{t-1}^2 + \alpha_2\varepsilon_{t-2}^2 + \cdots + \alpha_p\varepsilon_{t-q}^2 + \beta_1\sigma_{t-1}^2 + \cdots + \beta_q\sigma_{t-p}^2$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^{q} \alpha_1\varepsilon_{t-1}^2 + \sum_{i=1}^{p} \beta_1\sigma_{t-1}^2$$

- α_2 Existe homocedasticidad, y por lo tanto no existe efecto ARCH y GARCH
- e_{t-1}^2 Volatilidad de ayer. Si hubo grandes choques o perturbaciones entonces la varianza será mayor y que tanto las volatilidades pasadas impactan a las del presente.
- α_{t-1}^2 Varianza de la predicción de ayer. El efecto persiste por mucho tiempo.

También el autor Bollerslev (1986) agrega que la sumatoria de los errores rezagados y la volatilidad condicional rezagada mide la tasa a la cual estos efectos van disminuyendo en el tiempo y de que dicha persistencia es mayor o igual a uno será llamado un proceso integrado GARCH con persistencia explosiva.

Court y Rengifo (2011) explican que podría obtenerse varianzas condicionales negativas por que la no parsimonia del modelo, también es difícil determinar la cantidad óptima de rezagos a utilizar (***q***), pues no existe una aceptación sobre está y sostienen que "lo mejor a hacer es utilizar un modelo que es la generalización del modelo ARCH original y que de manera bastante

sencilla solucione los problemas mencionados", esto es el modelo ARCH generalizado, GARCH(p,q) y se expresa es de esta forma:

$$\begin{cases} u_t = z_t x \sigma_t \\ z_t \sim i.i.d.D(0,1) \\ \sigma_t^2 = \omega + \sum_{i=1}^{q} \alpha_i \ x \ u_{t-i}^2 + \sum_{j=1}^{p} \beta_j \ x \ \sigma_{t-j}^2 \end{cases} \quad (46)$$

Tanto el modelo GARCH como el modelo ARCH presenta condiciones de no negatividad siendo necesaria establecer restricciones para evitarlas. Una de las más utilizada es la función exponencial que permite al modelo GARCH cumplir la condición de no negatividad. Otro problema que presenta es la magnitud de los errores elevados al cuadrado que no permite los efectos que tiene el signo de las perturbaciones u errores, que a la vez contiene información valiosa para los inversores y en los mercados financieros se puede observar "la reacción de la volatilidad es mayor cuando ha ocurrido un evento inesperado negativo que cuando ha ocurrido un evento inesperado positivo. Esto implica que la varianza condicional es no simétrica".

Existen varias explicaciones posibles sobre la no simetría de la varianza. Por ejemplo, el efecto de apalancamiento que se refiere al hecho que cuando el precio de las acciones cae, el ratio de apalancamiento, definido como los pasivos divididos por el capital social de la empresa, crece. Desde el punto de vista de los accionistas, este incremento implica que los flujos de caja futuros son más inciertos, por lo que su reacción frente a caídas en los precios de las acciones, su respuesta frente a estos movimientos adversos será mucho más acentuada que en el caso de observarse movimientos al alza de los precios.

Este fenómeno se puede explicar por la teoría de la perspectiva (Prospect Theory) desarrollada por Kahneman y Tversky en 1979. Según esta teoría, los individuos toman sus decisiones de acuerdo a sus pérdidas y ganancias respecto a un nivel de referencia, que los individuos son más aversos a las pérdidas que a las ganancias del mismo tamaño y que las personas dan mucho peso a los eventos de baja probabilidad y menos probabilidad a los que ocurren con más frecuencia, es decir, que tienen

probabilidades no lineales. En conclusión, esta teoría puede explicar la asimetría en la volatilidad de las series de tiempo financieras (Court y Rengifo, 2011, p. 460).

2.3.4.5 Modelo de medición de volatilidad GARCH-con Variables exógenas. Guevara (2018) sostiene que se presenta un proceso autoregresivo en la varianza y de medias móviles en los choques a la varianza. Asimismo, introduce variables exógenas que puedan explicar los retornos o la varianza.

Por ejemplo, el siguiente GARCH(p,q) para la varianza de los retornos R_t:

$$R_t = c + X\beta + \varepsilon_t \sim N(0, h_t)$$

$$\varepsilon_t = \sqrt{h_t}\, v_t \sim N(0,1)$$

$$h_t = \alpha_0 + W\Phi + \alpha_1 \varepsilon_{t-1}^2 + \cdots + \alpha_1 \varepsilon_{t-q}^2 + \beta_1 h_{t-1} + \cdots + \beta_p h_{t-p}$$

Donde h_t es la varianza condicional de la serie. Los elementos autoregresivos están identificados por ε_{t-q}^2 y los elementos moving average por h_{t-p}, X son variables explicativas de los retornos y W son variables explicativas de la varianza.

2.3.4.6 Modelo de medición de volatilidad GARCH-M (GARCH en medias). Guevara (2018) (como se citó a Engle et al 1987), sostienen que este proceso asume que la volatilidad explica los movimientos de los retornos. La teoría detrás de este modelo es que una mayor incertidumbre, en principio, generaría que los retornos aumenten, ya que el riesgo de inversión es mayor.

Donde el modelo tiene la forma:

$$R_t = \mu_t + \varepsilon_t \sim N(0, h_t)$$

$$\mu_t = \gamma_0 + \delta_{ht}$$

$$\varepsilon_t = \sqrt{h_t} v_t \sim N(0,1)$$

$$h_t = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \cdots + \alpha_1 \varepsilon_{t-q}^2 + \beta_1 h_{t-1} + \cdots + \beta_p h_{t-p}$$

En este modelo:

Si, $\delta > 0$ existe aversión al riesgo en el instrumento

Si, $\delta = 0$ existe neutralidad al riesgo

Si, $\delta < 0$ existe propensión al riesgo

Sobre el modelo GARCH-M, Court y Rengifo (2011) afirman que en finanzas se presenta la relación entre riesgo y rentabilidad y por consiguiente a

mayor riesgo se exigirá más rentabilidad, “significa que la ecuación de la media condicional debe considerar el efecto de la varianza condicional. Si a media condicional se describe como un modelo AR(1) como el presentado en la ecuación 43, el modelo ARCH-M seria escrito como”:

$$y_t = \mu + \Phi_1 x\, y_{t-1} + \delta\, x\, \sigma_t^2 + \mu_t \qquad (47)$$

2.3.4.7 Modelo de medición de volatilidad TGARCH (Threshold ARCH). Bello (2017) (como se citó a Zakoian, 1994), precisa que Zakoian desarrolló los modelos Threshold ARCH (T-GARCH), donde tanto las noticias positivas y negativas presentan asimetría y que una aproximación T-GARCH es mostrada con la siguiente notación:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \gamma d_{t-1} \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$
$$\alpha_0 > 0, \alpha_1, \beta_1 \geq 0, 0 < (\alpha_1 + \beta_1) < 1$$

Donde:

$$d_t = \begin{cases} 1 \;\; e_t < 0 \text{ (Malas Noticias)} \\ 0 \;\; e_t \geq 0 \text{ (Buenas Noticias)} \end{cases}$$

Asimismo, el parámetro γ mide el impacto de la simetría, siendo conocidad como efecto de apalancamiento. Si es igual a cero (0) será un modelo GARCH estándar y que cuando existen noticias positivas (sock positivo) el efecto en la volatilidad es α_1, si por el contrario se presentan noticias negativas el efecto será $\alpha_{1-\gamma}$.

Por otra parte, Court y Rengifo (2011) sostienen que “el modelo TARCH (Threshold ARCH) fue desarrollado independientemente por Zakoian (1990) y Glosten, Jaganathan y Runkle (1993). (…) el modelo TARCH es además conocido como el modelo GJR. La forma que toma este modelo es la siguiente”:

$$\sigma_t^2 = \omega + \alpha\, x\, \mu_{t-1}^2 + \gamma x\, \mu_{t-1}^2 x\, d_{t-1} + \beta x\, \sigma_{t-1}^2 \qquad (48)$$

Donde:

$$d_{t-1} \begin{cases} 1 \text{ si } \mu_{t-1} < 0 \\ 0 \text{ de otra manera} \end{cases} \quad (49)$$

En este caso, Court y Rengifo (2011) consideran el modelo tanto "la magnitud de los errores al cuadrado, como el signo de los errores, entonces, tanto las noticias negativas (***u**t* < 0) y noticias positivas (***u**t* > 0) tienen diferentes impactos en la varianza condicional". Cuando se presentan noticias negativas, ***d**t* = 1, la varianza condicional tendrá la siguiente ecuación:

$$\sigma_t^2 = \omega + (\alpha + \gamma)\ x\ \mu_{t-1}^2 + \beta x\ \sigma_{t-1}^2 \quad (50)$$

Pero al presentarse noticias positivas la varianza condicional será igual a:

$$\sigma_t^2 = \omega + \alpha\ x\ \mu_{t-1}^2 + \beta x\ \sigma_{t-1}^2 \quad (51)$$

La ecuación anterior representa el modelo GARCH(1,1). Cuando es estadísticamente significativo y mayor que 0, se podrá afirmar la existencia del efecto de apalancamiento. Cuando la curva es asimétrica por el efecto de las noticias es porque el coeficiente es diferente de cero.

2.3.4.8 Modelos de medición de volatilidad EGARCH (Exponential GARCH). Para eliminar las restricciones o limitaciones al modelo original; surge también otra variante asimétrica conocida como modelo Exponencial GARCH o EGARCH. Bello (2017) señala que este modelo presentado por Nelson en 1991, para considerar la varianza condicional, presenta un modelo que tiene un comportamiento asimétrico tanto para las buenas y malas noticias.

Para el modelo EGARCH (1,1) se muestra la siguiente notación para calcular la volatilidad condicional heterocedástica.

$$\ln \sigma_t^2 = \delta_0 + \delta_1 \left|\frac{\varepsilon_{t-1}}{\sigma_{t-1}}\right| + \gamma \frac{\varepsilon_{t-1}}{\sigma_{t-1}} + \theta_1 \ln \sigma_{t-1}^2$$

Donde:

$$\sigma_t^2 = (\sigma_{t-1}^2)^{\theta_1} exp\left[\delta_0 + \delta_1 \left|\frac{\varepsilon_{t-1}}{\sigma_{t-1}}\right| + \gamma \frac{\varepsilon_{t-1}}{\sigma_{t-1}}\right]$$

Court y Rengifo (2011) agregan de esta manera: “El modelo Exponencial - GARCH o EGARCH fue desarrollado por Nelson en el año de 1991. Este modelo también captura el efecto del apalancamiento y la asimetría de la volatilidad condicional en respuesta a buenas y malas noticias, pero usando una diferente especificación. El modelo EGARCH se define como:

$$\ln \sigma_t^2 = \omega + \alpha\, x \left(\left| \frac{u_{t-1}}{\sigma_{t-1}} \right| - \sqrt{\frac{2}{\pi}} \right) + \gamma\, x \frac{u_{t-1}}{\sigma_{t-1}} + \beta\, x\, \log(\sigma_{t-1}^2) \qquad (52)$$

Se advierte que el EGARCH modela el logaritmo de la varianza condicional, por lo que el efecto de apalancamiento será exponencial. También, usando esta especificación se asegura que las varianzas condicionales nunca serán negativas.

En este modelo se afirma que existe el efecto de apalancamiento si $\gamma < 0$. Para comprender esto se observa que γ es el coeficiente del cociente del error respecto a la desviación estándar condicional, ambos del periodo ***t - 1***. Se advierte, que la desviación estándar condicional siempre es positiva, por lo que el signo del cociente depende solo de u_{t-1} . Por lo tanto, si en el periodo ***t - 1*** apareció una mala noticia ($u_{t-1} < 0$) y si $\gamma < 0$, y es estadísticamente significativo, el impacto de esta mala noticia incrementará la varianza condicional (esta vez expresada en términos de logaritmos). Finalmente, se aclara que el impacto de las noticias es asimétrico si $\gamma \neq 0$ y si es estadísticamente significativo.

Nelson, asumió en su modelo que los errores (***u***) seguían la distribución generalizada de los errores. EViews, supone por default que los errores siguen una distribución normal. Sin embargo, en EViews se puede cambiar la distribución de acuerdo a lo que sea más apropiado. La ecuación estimada por EViews, cuando se considera que los errores siguen una distribución normal, es la siguiente:

$$\ln(\sigma_t^2) = \omega + \alpha\, x \left| \frac{u_{t-1}}{\sigma_{t-1}} \right| + \gamma\, x \frac{u_{t-1}}{\sigma_{t-1}} + \beta\, x\, \log(\sigma_{t-1}^2) \qquad (53)$$

Finalmente, para órdenes superiores de este modelo, EViews asume el siguiente modelo”:

$$\ln(\sigma_t^2) = \omega + \sum_{i=1}^{q}\left(\alpha\, x\, \left|\frac{u_{t-1}}{\sigma_{t-1}}\right| + \gamma\, x \frac{u_{t-1}}{\sigma_{t-1}}\right) + \sum_{j=1}^{p} \beta_j\, x\, \log(\sigma_{t-j}^2) \qquad (54)$$

2.3.4.9 Modelos de medición de volatilidad PARCH (Power ARCH). Guevara (2018) (como se citó a Taylor 1986 y Schwert 1989), señala que este proceso modela la desviación estándar antes que la varianza. Asimismo, los autores detectaron que existe distintos grados de correlación para ε(d) para múltiples grados del parámetro d. Entonces estos modelos proponen estimar d.

El modelo tiene la forma:

$$R_t = c + \varepsilon_t \sim N(0, h_t)$$

$$\varepsilon_t = \sqrt{h_t}\, v_t \sim N(0,1)$$

$$\sqrt{h_t}^{\,d} = \alpha_0 + \alpha_1(|\varepsilon_{t-1}| - \gamma\varepsilon_{t-1})^d + +\beta_1\sqrt{h_{t-1}}^{\,d}$$

Donde d > 0 y |γ| <= 1. El parámetro d no es impuesto por el modelo, en este caso es directamente estimado.

Este modelo captura las asimetrías en distintos órdenes de potencia.

2.3.4.10 Modelos de medición de volatilidad CGARCH (Component GARCH). Guevara (2018) (como se citó a Ding y Granger 1996), Dice que el modelo de componentes permite que la media de la varianza que pueda cambiar con el tiempo:

El modelo tiene la forma:

$$R_t = c + \varepsilon_t \sim N(0, h_t)$$

$$\varepsilon_t = \sqrt{h_t}\, v_t \sim N(0,1)$$

$$h_t - m_t = \alpha_1(\varepsilon_{t-1}^2 - m_{t-1}) + \beta_1(h_{t-1} - m_{t-1})$$

$$m_t = \omega + \rho(m_{t-1} - \omega) + \emptyset(\varepsilon_{t-1}^2 - h_{t-1})$$

Donde ω es la varianza de largo plazo, m_t es la media cambiante y $h_t - m_t$ son las desviaciones transitorias del largo plazo.

Este modelo puede incluir también las asimetrías de los mercados financieros.

2.3.5 Redes Neuronales

Hanke y Wichern (2010), refiriéndose a los métodos de pronósticos convencionales, sostienen que la información del pasado es útil para pronosticar variables de interés que ayudarán a los negocios cumplir con sus objetivos estratégicos. En la forma de las distribuciones de la población a veces realizan supuestos que podrían estar sujetos a verificación, “La estimación de intervalos empleando un modelo de regresión, por ejemplo, supone que la población subyacente sigue una distribución normal”, Agregan además que.

> El campo en desarrollo de la inteligencia artificial intenta duplicar los procesos del cerebro y el sistema nervioso humanos usando la computadora. Si bien este campo se originó en la biología y la psicología, está avanzando rápidamente en otras áreas, lo que incluye los negocios y la economía. Los tres principales impulsores de la inteligencia artificial son el procesamiento del lenguaje, la robótica y las redes neurales artificiales. Este último campo es el que tiene más aplicaciones comerciales, incluyendo la de los pronósticos. En las redes neurales, muchos ejemplos que reflejan el rango completo de relaciones pasadas entre todas las variables que podrían afectar el resultado de las variables dependientes son programados en la computadora. El programa de la red neural asimila entonces estos ejemplos e intenta desarrollar las relaciones subyacentes a través del “aprendizaje” conforme los asimila. Este proceso de aprendizaje, llamado también *entrenamiento*, es análogo al entrenamiento para el aprendizaje en el trabajo. Unos cuantos investigadores de los pronósticos han notado la similitud entre las técnicas de las redes neurales y los métodos convencionales de pronósticos que intentan encontrar variables para predecir con éxito la variable dependiente. En teoría, la ventaja de las redes neurales como una herramienta para pronosticar es que las relaciones no necesitan especificarse con anticipación, puesto que el método implica el aprendizaje de las relaciones usando los ejemplos suministrados. Las redes neurales no requieren alguna suposición acerca de la distribución subyacente de la población y, a diferencia de muchos métodos convencionales de pronósticos, pueden operar con información incompleta. En ocasiones, la aplicación exitosa de una red neural se conoce como *plug-compatible.* Esto significa que el programa de la red

> neural puede sustituir rápida y fácilmente y sin ningún problema el modelo actual, como un análisis de regresión. Algunas veces es posible obtener una mejora en el desempeño, como mayor exactitud en los pronósticos, por ejemplo, con un efecto mínimo en las operaciones en curso. Las redes neurales son especialmente valiosas cuando los datos están fuertemente correlacionados, o no existen, y cuando los sistemas son notoriamente no lineales (Hanke y Wichern, 2010, p.489).

Mun (2016) escribe con respecto a la teoría de las redes neuronales, la expresión Red Neuronal es usada al hablar de "una red o circuito de neuronas biológicas", pero en estos tiempos, en un ambiente cibernético recrea las redes neuronales artificiales que a la vez son nodos o neuronas artificiales. "Estas redes tratan de imitar las neuronas en el cerebro humano en formas de patrones de pensamiento e identificación y, en este caso, identificando patrones para efectos de pronóstico de series de tiempo". Para modelar con redes neuronales el autor afirma lo siguiente:

> En el Simulador de Riesgo, conocido como Risk Simulator, la metodología se encuentra dentro del módulo ROV BizStats ubicado en Simulador de Riesgo | ROV BizStats | Pronóstico de Redes Neuronales, así como en Simulador de Riesgo | Pronóstico | Redes Neuronales. Agrega además tener en cuenta que el número de capas ocultas en la red es un parámetro de entrada y tendrá que ser calibrado con sus datos. Por lo general, cuanto más complicado es el patrón de datos, mayor es el número de capas ocultas que se podrían necesitar y tomaría más tiempo calcular (Mun, 2016, p.467).

Mun (2016) recomienda empezar en 3 capas. Para la etapa de prueba será "simplemente el número de puntos de datos utilizados en la calibración final del modelo de Red Neuronal, y recomienda el uso de al menos el mismo número de períodos que se quieren pronosticar que el período de prueba".

De la Cruz (2018), asegura que las Redes Neuronales Artificiales, son los modelos más usados para las series de tiempo por las siguientes razones:

- Los pronósticos se elaboran con base al comportamiento pasado de la variable de interés.

- Cálculo de intervalos de confianza para la predicción.
- En el caso de series de tiempo multivariadas las variables son de tipo cuantitativas.

De la Cruz (2018), agrega que son fundamentos de las Redes Neuronales, el deseo de imitar la capacidad del cerebro humano para el reconocimiento de patrones a través de una computadora, la misma que se muestra en la figura 2.9.

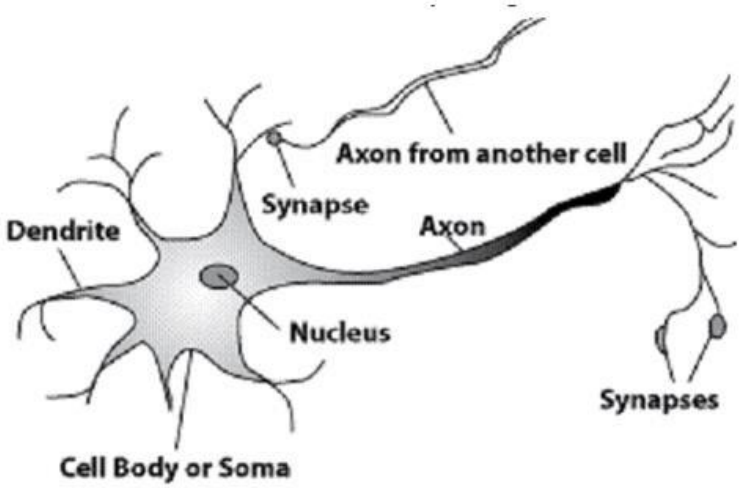

Figura 2.9 Fundamentos de las Redes Neuronales
Fuente. De La Cruz (2018)

Con respecto a la Topología, la misma autora sostiene que las neuronas artificiales, también llamados nodos se organizan en capas de tres tipos, una capa de entrada, varias capas ocultas y una capa de salida, según la figura 2.10.

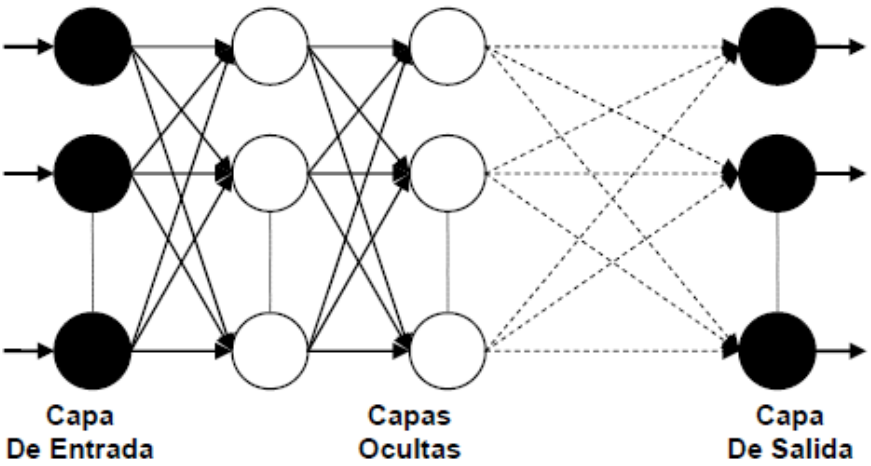

Figura 2.10 Topología de las Redes Neuronales

Fuente. De La Cruz (2018)

De La Cruz (2018) agrega que los tipos de redes disponibles en NeuralTools de la suite de Palisade son las siguientes:

1. Redes neuronales de regresión generalizada / Redes neuronales probabilísticas.

2. Redes Multicapa de Propagación hacia delante.

3. Búsqueda de la mejor Red. NeuralTools prueba varias configuraciones de red. La selección de la mejor red se basa en el menor error obtenido en los datos de la prueba.

Asimismo, presenta un modelo de redes neuronales, de acuerdo a la figura 2.11, denominada preparación del Modelo

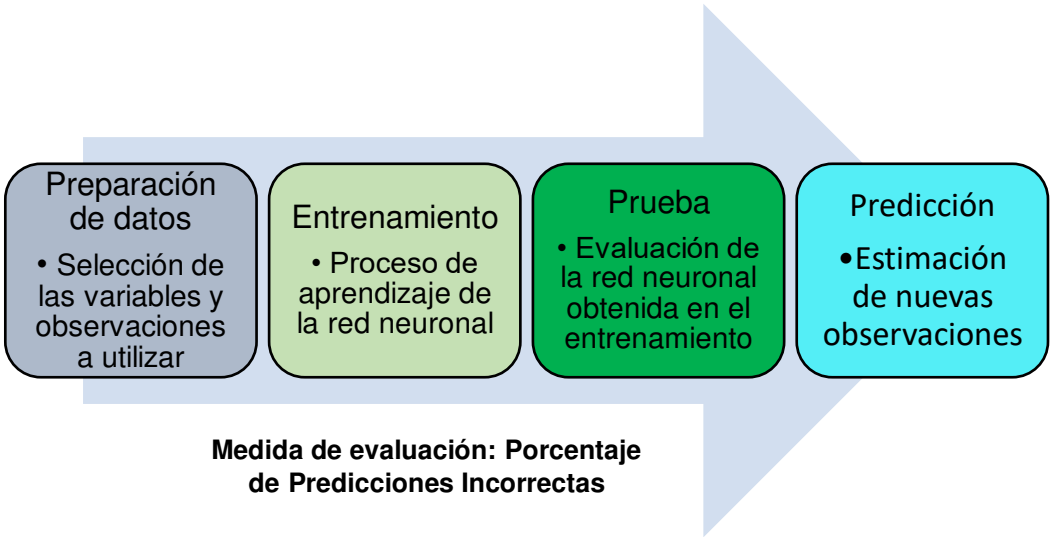

Figura 2.11 Preparación del Modelo
Fuente. De La Cruz (2018)

Por otra parte, para los datos de entrenamiento y prueba indica que Los datos de entrenamiento y prueba deben dividirse de acuerdo a una fecha dada. La autora hace uso del NeuralTools es un programa que utiliza redes neuronales dentro de Microsoft Excel.

2.3.6 Glosario

ASIMETRIA: Wooldrigde (2010) “Medida de que tan lejos está una distribución

de ser simétrica, con base en el tercer momento de la variable aleatoria estandarizada".

CAMINATA ALEATORIA: Wooldrigde (2010) "Proceso de series de tiempo donde el valor del periodo siguiente se obtiene como el valor de este periodo, más un error independiente (o al menos uno no correlacionado)".

CAMINATA ALEATORIA CON TENDENCIA ESTOCASTICA: Wooldrigde (2010) "Caminata aleatoria que tiene una constante (o tendencia) en cada periodo".

EGARCH (Exponential GARCH): Modelo de Nelson (1991), introduce asimetrías en los choques de información. Este proceso modela en logaritmo de la varianza antes que la varianza en sí misma, pero permite una mayor flexibilidad en la estimación. Guevara (2018).

ESTACIONARIEDAD: Es una condición estadística de una variable aleatoria, que consiste en que la variable no deambule en torno a un valor predeterminado en el tiempo. Más bien, para que una variable sea estacionaria esta debe girar en torno a una media, sin presentar comportamientos erráticos o atípicos. Trujillo (2010)

EXCESO DE CURTOSIS: Los retornos tienen alta concentración alrededor de los valores centrales de la variable. Estos fenómenos fueron detectados inicialmente por Mandelbrot (1963) y Fama (1963).

EXISTENCIA DE AGRUPAMIENTO O CLUSTERS: Mandelbrot (1963), Engle (1983), "Periodos de alta y baja volatilidad. Si la volatilidad es alta en un periodo, tiende a seguir siéndolo; si es baja en un periodo tiende a seguir siendo baja en el periodo siguiente".

GARCH-M: Proceso de Engle, Lilien, y Robins, asume que la volatilidad explica los movimientos de los retornos. La teoría detrás de este modelo es que una mayor incertidumbre, en principio, generará que los retornos aumenten, ya que el riesgo de inversión es mayor. Guevara (2018).

GENERALIZACIÓN AUTORREGRESIVO DE HETEROSCEDASTICIDAD CONDICIONAL (GARCH):

Se utiliza para modelar históricos y futuras predicciones de niveles de volatilidad de un valor comercializable (por ejemplo, precios de las acciones, precios de commodities, precios del petróleo, etc.). El conjunto de datos tiene que ser una serie de tiempo de los niveles de precios brutos. GARCH primero convierte los precios en rentabilidad relativa y luego ejecuta una optimización interna para ajustar los datos históricos a una estructura de plazo de volatilidad de reversión a la media mientras se asume que la volatilidad es heterocedástica por naturaleza (Mun, 2016, p.458).

GJR (GLOSTEN, JAGANNATHAN & RUNKLE GARCH): El GJR-GARCH, o simplemente GJR, modelo de Glosten, Jagannathan & Runkle de 1993, permite la varianza condicional responder de manera diferente a las innovaciones positivas y negativas pasadas. Bollerslev (2008).

HETEROSCEDASTICIDAD: Gujarati y Porter (2010) "Donde la varianza condicional de la población Y varía con X. Esta situación se conoce apropiadamente como heteroscedasticidad, o dispersión desigual, o varianza desigual".
Wooldrigde (2010) "La varianza del término del error, dadas las variables explicativas, no es constante".

HETEROSCEDASTICIDAD CONDICIONAL AUTORREGRESIVA (ARCH): Wooldrigde (2010) "Modelo de heterocedasticidad dinámica en que la varianza del término del error, dado la información pasada, depende linealmente de los errores cuadrados".

MODELO: Descripción simplificada y práctica del funcionamiento de algo o de la vida real. Raffo (2012)

PROCESO ESTACIONARIO: Wooldrigde (2010) "Procesos de series de tiempo donde las distribuciones marginales y conjuntas son invariables en el tiempo".

PROCESO ESTOCASTICO: Court y Rengifo (2011) "Un proceso estocástico es una secuencia de números aleatorios. El proceso estocástico se escribirá como { yi } para i = 1, 2,… Si este índice representa tiempo, el proceso estocástico se llamará serie de tiempo".

Wooldrigde (2010) “Secuencia de variables aleatorias indexadas con base en el tiempo”.

REDES NEURONALES ARTIFICIALES: Mun (2016) “en un entorno de software. Estas redes tratan de imitar las neuronas en el cerebro humano en formas de patrones de pensamiento e identificación y, en este caso, identificando patrones para efectos de pronóstico de series de tiempo”.

RUIDO BLANCO: Gujarati y Porter (2010) “Se dice que un proceso es puramente aleatorio o de ruido blanco si tiene una media igual a cero, una varianza constante σ^2 y no está serialmente correlacionado”.
Trujillo (2010) “Se caracteriza por ser estacionario en media y varianza, asimismo, los errores no están autocorrelacionados”.

SIMULACION: Raffo (2012) “Forma de estudiar un sistema, mediante la utilización de un modelo”.

SIMULACION MONTE CARLO: Resuelve rápidamente problemas complejos.

> De una manera sencilla, la simulación Monte Carlo crea un futuro artificial al generar miles e incluso cientos de miles de caminos posibles de resultados y analiza sus características predominantes. En la práctica, los métodos de la simulación Monte Carlo son utilizados para el análisis de riesgo, cuantificación del riesgo, análisis de sensibilidad y predicción (Mun, 2016, p.105).

TGARCH: Los modelos que son capaces de reproducir efectos asimétricos son los llamados modelos TGARCH, (*Threshold Heteroskedastic Autoregresive Models*) son modelos que dependen de un umbral (threshold) por medio del cual definen su reacción. Este modelo fue introducido por primera vez por Glosten, Jagannathan y Runkle (1993), quienes consideraron una especificación para la varianza condicional distinta a las planteadas anteriormente.

CAPITULO 3. METODOLOGIA

3.1 Hipótesis general

Mediante la aplicación de modelos condicionados a su pasado, se pronosticarán adecuadamente los precios de las acciones de Telefónica cotizadas en la New York Stock Exchange (NYSE).

3.2 Hipótesis específicas

1. La diferenciación de los precios de cierre influye directamente en la media de los retornos de las acciones de Telefónica.
2. El nivel de volatilidad influye directamente en la varianza de los retornos de las acciones de Telefónica.
3. Los niveles de noticias influyen directamente en el tipo de asimetría de la volatilidad de los retornos de las acciones de Telefónica.
4. Los valores extremos de los retornos de las acciones influyen directamente en el tipo curtosis de la volatilidad de los retornos de las acciones de Telefónica.

3.3 Identificación de variables

Ramón y López (2016) dicen que un proceso estocástico es una sucesión de variables aleatorias (Y_t) “que evolucionan en función de otra variable, generalmente el tiempo. Cada una de las variables aleatorias del proceso tiene su propia función de distribución de probabilidad y, entre ellas, pueden estar correlacionadas o no”.

Larios, Gonzáles y Alvarez (2016) refiriéndose a la volatilidad condicional aseguran que una variable dependiente es la serie de tiempo financiera Índice

de bonos de mercados emergentes de Perú (Riesgo-país) y cuya única variable independiente es su valor pasado en 22 meses.

De acuerdo al cuadro adjunto se describen tanto las variables independientes (predictivas) y dependientes (predictoras)

Cuadro 3.1 **Identificación de variables**

VARIABLES	INDICADORES
INDEPENDIENTE: Modelos de pronóstico condicionados a su pasado DEPENDIENTE: Precio de las acciones	$Y_{t+1}=\mathrm{Y_t}+e_{t+1}$
INDEPENDIENTE: Diferenciación de precios DEPENDIENTE: Media de los retornos	$\mathrm{LN}\left(\frac{\mathrm{Y_t}}{\mathrm{Y_{t+1}}}\right)$
INDEPENDIENTE: Nivel de volatilidad DEPENDIENTE: Varianza de los retornos	$\sigma_t^2 = \alpha_0 + \alpha_1\varepsilon_{t-1}^2 + \alpha_2\varepsilon_{t-2}^2 + \cdots + \alpha_p\varepsilon_{t-q}^2 + \beta_1\sigma_{t-1}^2 + \cdots + \beta_q\sigma_{t-p}^2$
INDEPENDIENTE: Nivel de noticias DEPENDIENTE: Asimetría de la volatilidad	$\sigma_t^2 = \omega + \alpha x\mu_{t-1}^2 + \gamma x\mu_{t-1}^2 + d_{t-1} + \beta x\mu_{t-1}^2$
INDEPENDIENTE: Valores extremos DEPENDIENTE: Curtosis de la volatilidad	$\sigma_t^2 = \omega + \alpha x\mu_{t-1}^2 + \gamma x\mu_{t-1}^2 + d_{t-1} + \beta x\mu_{t-1}^2$

Fuente. Elaboración propia

3.3.1 Variables independientes o predictora

Modelos de pronóstico condicionados a su pasado.

1. Diferenciación de precios.
2. Nivel de volatilidad.
3. Nivel de noticias.

4. Valores extremos.

3.3.2 Variables dependientes o predictiva

Precio de acciones

1. Media de los retornos.
2. Varianza de los retornos.
3. Asimetría de la volatilidad.
4. Curtosis de la volatilidad.

3.4 Matriz de consistencia

Con el cuadro adjunto se formula la matriz de consistencia:

Cuadro 3.2 **Matriz de consistencia**

PROBLEMAS	OBJETIVOS	HIPÓTESIS	VARIABLES	INDICADORES
¿Cómo aplicar modelos condicionados a su pasado para pronosticar adecuadamente los precios de las acciones de Telefónica cotizadas en la New York Stock Exchange (NYSE)?	Determinar cómo aplicar modelos condicionados a su pasado para pronosticar adecuadamente los precios de las acciones de Telefónica cotizadas en la New York Stock Exchange (NYSE)	Mediante la aplicación de modelos condicionados a su pasado, se pronosticarán adecuadamente los precios de las acciones de Telefónica cotizadas en la New York Stock Exchange (NYSE)	INDEPENDIENTE: Modelos condicionados a su pasado DEPENDIENTE: Precio de las acciones	$Y_{t+1}=\mathrm{Y_t}+e_{t+1}$
¿Cómo la diferenciación de los precios de cierre influirá en la media de los retornos de las acciones de Telefónica?	Determinar cómo influye la diferenciación de los precios de cierre en la media de los retornos de las acciones de Telefónica	La diferenciación de los precios de cierre influye directamente en la media de los retornos de las acciones de Telefónica	INDEPENDIENTE: Diferenciación de precios DEPENDIENTE: Media de los retornos	$\mathrm{LN}\left(\frac{\mathrm{Y_t}}{\mathrm{Y_{t+1}}}\right)$
¿Cómo el nivel de volatilidad identificará la varianza de los retornos de las acciones de Telefónica?	Determinar cómo influye el nivel de volatilidad en la varianza de los retornos de las acciones de Telefónica	El nivel de volatilidad influye directamente en la varianza de los retornos de las acciones de Telefónica	INDEPENDIENTE: Nivel de volatilidad DEPENDIENTE: Varianza de los retornos	$\sigma_t^2 = \alpha_0 + \alpha_1\varepsilon_{t-1}^2 + \alpha_2\varepsilon_{t-2}^2 + \cdots + \alpha_p\varepsilon_{t-q}^2 + \beta_1\sigma_{t-1}^2 + \cdots + \beta_q\sigma_{t-p}^2$
¿Cómo los niveles de noticias identificarán la asimetría de la volatilidad de los retornos de las acciones de Telefónica?	Determinar cómo influyen los niveles de noticia en la asimetría de la volatilidad de los retornos de las acciones de Telefónica	Los niveles de noticias influyen directamente en el tipo de asimetría de la volatilidad de los retornos de las acciones de Telefónica	INDEPENDIENTE: Nivel de noticias DEPENDIENTE: Asimetría de la volatilidad	$\sigma_t^2 = \omega + \alpha x\mu_{t-1}^2 + \gamma x\mu_{t-1}^2 + d_{t-1} + \beta x\sigma_{t-1}^2$
¿Cómo los valores extremos de los retornos identificarán la curtosis de la volatilidad de las acciones de Telefónica?	Determinar cómo influyen los valores extremos de los retornos en la curtosis de la volatilidad de las acciones de Telefónica	Los valores extremos de los retornos influyen directamente en el tipo curtosis de la volatilidad de las acciones de Telefónica	INDEPENDIENTE: Valores extremos DEPENDIENTE: Curtosis de la volatilidad	$\sigma_t^2 = \omega + \alpha x\mu_{t-1}^2 + \gamma x\mu_{t-1}^2 + d_{t-1} + \beta x\mu_{t-1}^2$

Fuente. Elaboración propia

(*) La demostración de cada variable se muestra en el cuadro 3.4

3.5 Tipo y Diseño de Investigación

Niño (2011) Clasifica las investigaciones de acuerdo al nivel de generalización y el tipo de objetivo.

> Según el nivel de generalización describe una investigación como “Pura” o “Fundamental” cuando se propone el desarrollo de teorías por medio del descubrimiento de generalizaciones o principios.
>
> Según el objetivo, habla de la investigación descriptiva por que el objetivo de una investigación es encontrar todas las características y circunstancias que conforman una determinada situación problemática de manera que se consiga una relación precisa de la realidad, se trata de una investigación descriptiva. Asimismo, distingue tipos de estudios descriptivos, pues una investigación descriptiva puede orientarse el estudio y recolección de datos de diferentes formas, según el objetivo que se persigue. Dentro de esta distingue el análisis predictivo como un tipo de estudio descriptivo en el cual se parte de estudios longitudinales que indican lo que ha sucedido en el pasado y lo que sucede actualmente para predecir, a partir de esos datos, lo que sucederá en el futuro (Niño, 2011, p.s/p).

En el diseño de investigación, la autora desarrolla el diseño experimental.

Ñaupas et al (2014) indican que muchos investigadores científicos dividen la investigación en dos partes:

1. “La investigación básica, pura o fundamental”, que busca descubrir nuevos conocimientos. Asimismo, dentro de esta distingue los siguientes niveles: exploratoria, descriptiva, explicativa y predictiva; esta última tienes fines de predicción o futurización.
2. “La investigación aplicada”, que busca resolver objetivamente los problemas que aquejan a la sociedad.

> Se llaman aplicadas porque con base en la investigación básica, pura o fundamental, en las ciencias fácticas o formales, que hemos visto, se formulan problemas e hipótesis de trabajo para resolver los problemas de la vida productiva de la sociedad. Se llama también tecnológica porque su producto no es un conocimiento puro, científico sino tecnológico (Ñaupas

et al, 2014, p.s/n).

El diseño de investigación es no experimental.

Sánchez y Reyes (2015), identifican dos clasificaciones; por un lado: La investigación básica que busca nuevos conocimientos y, la investigación aplicada que le preocupa la aplicación inmediata sobre una realidad circunstancial antes que el desarrollo de un conocimiento de valor universa: Por otro lado: la investigación sustantiva y la investigación tecnológica. Con respecto al diseño de investigación, los autores sostienen que este concepto, ha sido estudiado y se adecúa más para el caso de los estudios experimentales por ser éstos de mayor control y validez, sin embargo, también pueden organizarse en las investigaciones que emplean el método descriptivo, aunque con las limitaciones respectivas. En resumidas cuentas, al diseño de investigación lo clasifican en diseños experimentales y diseños no experimentales.

Larios, Álvarez y González (2016) de acuerdo a sus hallazgos sostienen lo siguiente:

> En el marco de la investigación, el investigador debe decidir acerca del tipo de investigación que se realizará: si es de análisis cualitativo o de análisis cuantitativo. En el caso del análisis cuantitativo, se refiere fundamentalmente a la aplicación de la econometría, mediante la cual se propone explicar relaciones de causalidad con base en un determinado marco teórico a ser comprobado, con datos históricos de fuentes oficiales o confiables, (…). Se procesa el análisis mediante el procedimiento formal de tratamiento de los datos, para luego analizar los resultados, comprobando el cumplimiento de determinados parámetros a fin de verificar las hipótesis respectivas (Larios, Álvarez y González, 2016, p.s/p).

Hernández y Mendoza (2018), afirman “Los enfoques cuantitativo, cualitativo y mixto constituyen rutas posibles para resolver problemas de investigación. Todos resultan igualmente valiosos y son, hasta ahora, los mejores métodos para investigar y generar conocimientos” (p.2). Los mismos autores sostienen que “Existen diferentes clasificaciones para los diseños cuantitativos, pero las más sencilla y citada es la que se muestra en la figura 7.1”

(p.151). Esto se puede apreciar en la figura 3.1.

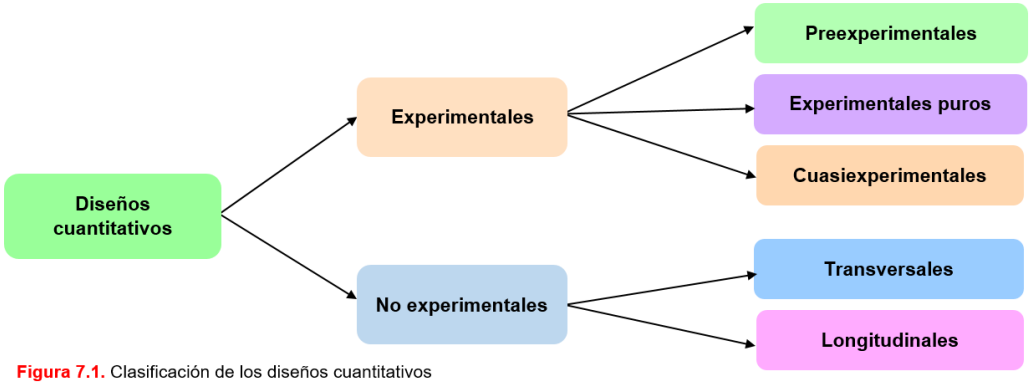

Figura 3.1 Clasificación de los diseños cuantitativos
Fuente. Tomado de Hernández y Mendoza (2018)

Entonces, el diseño de investigación en el enfoque cuantitativo identifica como experimentales y no experimentales o múltiple. Con referencia a este último indica que no se manipulan las variables pues los fenómenos ya sucedieron, está a su vez, se subdividen en transversales y longitudinales o evolutiva, que tiene varias mediciones a lo largo del tiempo y que se dividen en tres clases genéricas: tendencia, de evolución de grupo y del panel. La diferencia de la tendencia con respecto a las otras es que la recolección de datos de una población es la misma, pero las muestras son distintas.

Esta investigación pretende contribuir con solucionar problemas que afectan a la sociedad y como parte de esta a los inversionistas, por tanto se considera de tipo aplicativo, enfoque cuantitativo y diseño no experimental, pues pretende explicar el comportamiento de una serie temporal y luego pronosticar los retornos y la volatilidad de los precios de cierre diario de las cotizaciones de las acciones de la compañía Telefónica de España (Telefónica S.A) que se cotizan en la plaza de New York Stock Exchange (NYSE) con la nomenclatura TEF.

Ramón y López (2016) refiriéndose a series temporales, sostienen que estas construyen modelos para explicar la estructura o describir el comportamiento de una variable durante un periodo de observación y prever su evolución. El esquema del presente proyecto como primer nivel, se enfocará a

series de tiempo univariadas el mismo que se muestra a continuación:

Cuadro 3.3 **Esquema de series de tiempo univariado**

NOMBRE ESQUEMA	ESQUEMA
Series de tiempo	$P_{t-n}, \dots, P_{t-2}, P_{t-1}, P_t, P_{t+1}, P_{t+2}, P_{t+3}$
Observaciones reales (Dentro de muestra)	$O_{t-n}, \dots, O_{t-2}, O_{t-1}$
Observaciones reales (Fuera de muestra)	$O_t, O_{t+1}, O_{t+2}, O_{t+3}$
Medición del error	$e_t = O_t - P_t$

Fuente. Elaboración propia

En donde:

O: Observación o resultado de la serie temporal

P: Pronóstico de la serie temporal

e: Medición del error o error del pronóstico.

3.6 Unidad de análisis

Son las acciones de la compañía Telefónica S.A. que cotizan en la bolsa de la plaza de New York Stock Exchange (NYSE).

3.7 Población de estudio

Para conocer la población de las plazas donde Telefónica S.A. cotiza sus acciones, se consultó en su propio sitio web el siguiente enlace https://www.telefonica.com/es/web/shareholders-investors/la_accion/presencia-en-bolsas y de acuerdo a Telefónica (2017), esta tiene presencia en las siguientes plazas: Buenos Aires, Lima, Londres, Madrid y Nueva York.

3.8 Tamaño de muestra

Son las acciones de Telefónica S.A. (TEF) tomadas desde el 03 de enero del 2000 al 01 de agosto del 2018 del sitio web https://es.finance.yahoo.com/quote/TEF/history?p=TEF de la plaza de New York Stock Exchange (NYSE).

3.9 Selección de muestra

Se dificulta el acceso a todas las observaciones, pero investigaciones científicas recomiendan la mayor cantidad de observaciones, en este caso se investigó a partir de 4,802 observaciones del precio de cierre de las cotizaciones diarias, que están dentro del 03 de enero del 2000 al 01 de agosto del 2018 siendo, por tanto:

1. Muestras no aleatorias y
2. Muestra por conveniencia o intencional.

Los criterios considerados para la selección de la plaza de New York Stock Exchange (NYSE), por ser el principal centro financiero del mundo y por sus altas transacciones que se realizan diariamente y su fácil accesibilidad para la obtención de los datos del sitio web https://es.finance.yahoo.com/quote/TEF/history?p=TEF.

3.10 Técnicas de recolección de Datos

Fueron obtenidos a través de la web https://es.finance.yahoo.com/quote/TEF/history?p=TEF de la nomenclatura TEF que corresponden a las acciones del Telefónica que se cotizan en la plaza de New York Stock Exchange (NYSE)

3.11 Análisis e interpretación de la información

Haciendo uso de la metodología Box y Jenkins o ARIMA, se eliminó la tendencia que presentaba la serie original de TEF, entonces los retornos y la volatilidad fueron calculados con el logaritmo de las diferencias de los precios diarios, esta operación dio como resultado el valor del retorno. Con este proceso de diferenciación, la serie se convirtió en estacionaria utilizando el software econométrico EVIEWS 10 y los simuladores NeuralTools y Risk simulator. Se pronosticó la volatilidad a través de las diversas variedades de los modelos de la familia GARCH. Por defecto, se partió del GARCH (1, 1), se plantearon otros modelos alternativos de GARCH. Para los ajustes de los resultados de los modelos, se utilizaron las siguientes herramientas:

A) Pruebas de ratio de verosimilitud y

B) Criterios de Información de Akaike y el Bayesiano.

Para el presente proyecto, se probaron por ensayo y error diversos modelos de heteroscedasticidad.

A continuación, se presenta cuadro de datos de resumen del análisis de datos

Cuadro 3.4 **Cuadro de análisis de datos**

VARIABLE	INDICADOR	NIVEL DE MEDICION	ESTADISTICOS DESCRIPTIVOS	ESTADISTICO DE CONTRASTE
Hipótesis general: Mediante la aplicación de modelos condicionados a su pasado se pronosticarán adecuadamente los precios de las acciones de Telefónica en la New York Stock Exchange (NYSE)	$Y_{t+1} = Y_t + e_{t+1}$	De razón o proporción	Media y Varianza	ARCH(q) y GARCH(p,q)
Hipótesis especifica 1: La diferenciación de los precios de cierre influye directamente en la media de los retornos de las acciones de Telefónica	$\mathrm{LN}\left(\frac{Y_t}{Y_{t+1}}\right)$	De razón o proporción	Media	prueba t para la igualdad de medias
Hipótesis especifica 2: El nivel de volatilidad influye directamente en la varianza de los retornos de las acciones de Telefónica	$\sigma_t^2 = \alpha_0 + \alpha_1\varepsilon_{t-1}^2 + \alpha_2\varepsilon_{t-2}^2 + \cdots + \alpha_p\varepsilon_{t-q}^2 + \beta_1\sigma_{t-1}^2 + \cdots + \beta_q\sigma_{t-p}^2$	De razón o proporción	Varianza	Prueba de Levene de igualdad de varianzas
Hipótesis especifica 3: Los niveles de noticias influyen directamente en el tipo de asimetría de la volatilidad de los retornos de las acciones de Telefónica	$\sigma_t^2 = \omega + \alpha x \mu_{t-1}^2 + \gamma x \mu_{t-1}^2 + d_{t-1} + \beta x \mu_{t-1}^2$	De razón o proporción	Asimetría	Prueba de normalidad de Jarque-Bera para la asimetría
Hipótesis especifica 4: Los valores extremos de los retornos de las acciones influyen directamente en el tipo curtosis de la volatilidad de los retornos de las acciones de Telefónica	$\sigma_t^2 = \omega + \alpha x \mu_{t-1}^2 + \gamma x \mu_{t-1}^2 + d_{t-1} + \beta x \mu_{t-1}^2$	De razón o proporción	Curtosis	Prueba de normalidad de Jarque-Bera para la curtosis

Fuente. Elaboración propia

Se modeló y pronosticó la volatilidad con el paquete econométrico Eviews 10, que Giron (2018), lo define como un paquete econométrico fácil y sencillo, que proporciona muchas herramientas utilizadas en econometría y series de tiempo. El ajuste de los modelos del estadístico de contraste se realizó con las siguientes herramientas:

A) Pruebas de ratio de verosimilitud y

B) Criterios de Información de Akaike y el Bayesiano.

Los resultados obtenidos con los modelos de la familia GARCH, se compararon con los resultados del modelo predictivo de Redes Neuronales Artificiales para lo cual se utilizó los softwares:

- NeuralTools. - Es un programa que utiliza redes neuronales dentro de Microsoft Excel y es uno de los softwares de Palisade.

Posee las siguientes ventajas:

1 Pueden modelar de forma correcta patrones de datos complejos.
2 Pueden incorporar variables independientes de distintos tipos.
3 Pueden realizar predicciones en vivo.
4 Pueden ser insensibles cuando existen valores atípicos.

- Risk simulator. - Es un software de simulación Monte Carlo, Pronóstico y Optimización. Este software está escrito en Microsoft.NET C# y funciona junto con Excel como un complemento.

La demostración de las hipótesis especificas uno y dos, fueron realizadas con el paquete estadístico SPSS Statistics 25.

La demostración de las hipótesis especificas tres y cuatro, se realizó con el paquete econométrico Eviews 10 y el apoyo del paquete estadístico Minitab 19.

CAPITULO 4. RESULTADOS Y DISCUSIÓN

4.1 Análisis de resultados

Esta investigación describe el desenvolvimiento de una serie temporal univariada a través de su historia buscando pronosticar sus rendimientos. Cuando se tiene un modelo de rendimientos, esta deberá estar en función de una media o un comportamiento constante a largo plazo, pero antes necesita estabilizar su media y su varianza o, dicho de otro modo, convertirlas en estacionaria en sentido débil.

Este proceso de conversión estacionaria fue realizada con las metodologías de Box y Jenkins, y que necesita que una serie de tiempo está en función de su pasado y que se basan en modelar la media condicional y la varianza condicional simultáneamente, se aplicó al precio de cierre ajustado de las acciones de Telefónica S.A. que se cotizan en la Bolsa de Nueva York (New York Stock Exchange, NYSE) al analizar la evolución del precio de cierre de Telefónica S.A. con la nomenclatura TEF, desde 02 de enero del año 2000 hasta 01 de agosto del 2018 en niveles, posteriormente con la ayuda del paquete econométrico Eviews versión 10, se diferenciaron estas series para transformarlo en estacionaria y así explicar su comportamiento. Según Gujarati y Porter (2010), cuando “una serie de tiempo es no estacionaria, la media o la varianza o ambas son variantes en el tiempo” y por tanto estas series de tiempo deben ser estacionarias.

Este tipo de series como las producidas por las variables financieras de la TEF, no pueden ser modelados con las técnicas de pronóstico tradicionales, si no con modelos de series de tiempo univariadas, o ARIMA conocidas también

como metodologías Box y Jenkins, también Box, Jenkins y Reinsel (2008) sostienen la necesidad de que las series sean estables en el tiempo. Esta metodología tiene cuatro pasos: la identificación, la estimación, la validación y el pronóstico.

4.1.1 Metodología Box y Jenkins

En esta parte, se verifican si la serie es estacionaria con pruebas de Raíz Unitaria (RU) y si tienen ruido blanco o tiene memoria, donde la media es igual a 0 $E(Y_t) = 0$, la varianza es constante $Var(Y_t) = \sigma^2$ y la autocovarianza es igual a 0 $Cov(Y_t, Y_{t-j}) = 0, \forall\, j \neq 0$, para poder pronosticar.

En este caso, la serie original de TEF no es estacionaria, se tiene que diferenciarlas para estabilizarlas. En la Figura 4.1 se aprecia que el comportamiento del precio de cierre de las acciones de TEF no es una serie estacionaria y presenta tendencia y tanto la media y la varianza no es constante a lo largo del periodo, y para tener retornos esperados o promedios y varianza constante, deberán diferenciarse tantas veces sea necesaria la serie original de TEF, a fin de asignarle un comportamiento estacionario.

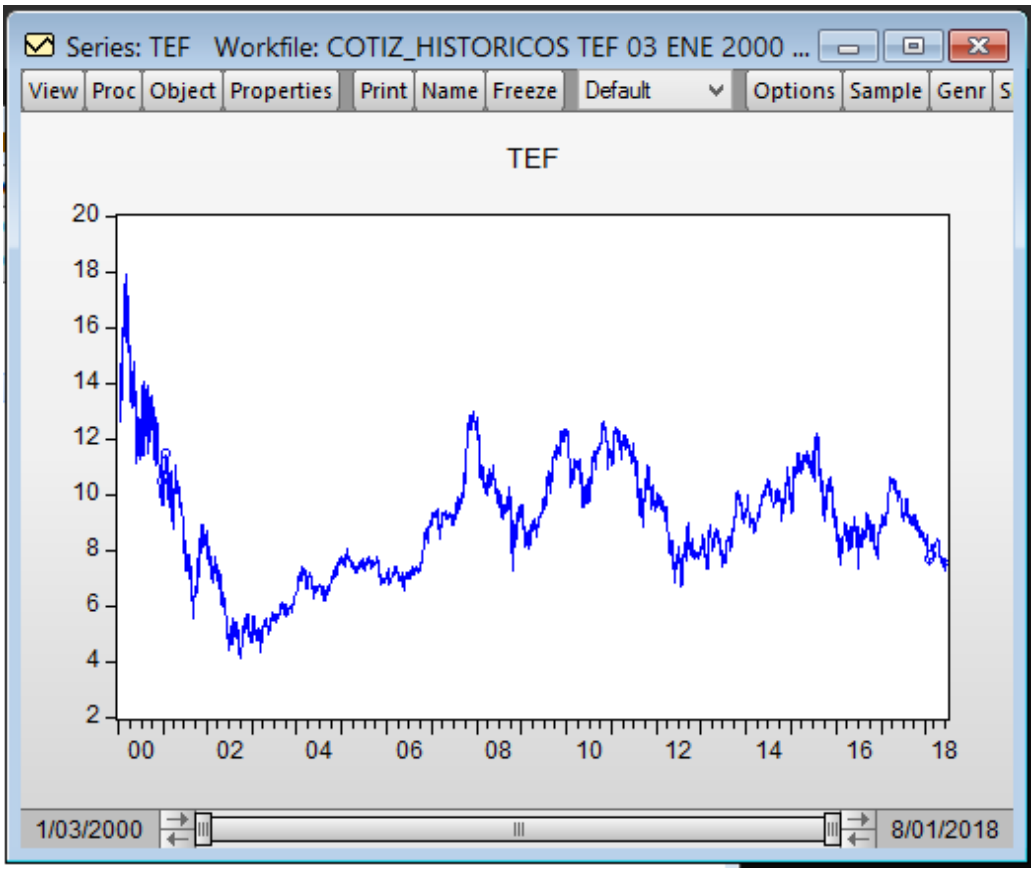

Figura 4.1 *Características para observar comportamiento de la serie TEF*

Fuente. Elaboración propia, empleando Eviews 10

También se observan los resultados del histograma de frecuencias de la variable de Telefónica, y tiene un comportamiento asimétrico pues hay un sesgo positivo de 0.35 y es leptocúrtica 3.45, vale decir que hay un comportamiento asimétrico en dicha serie de precios dado los efectos de la volatilidad para modelar los efectos de noticias positivas o negativas, tal podemos apreciar en la figura 4.2.

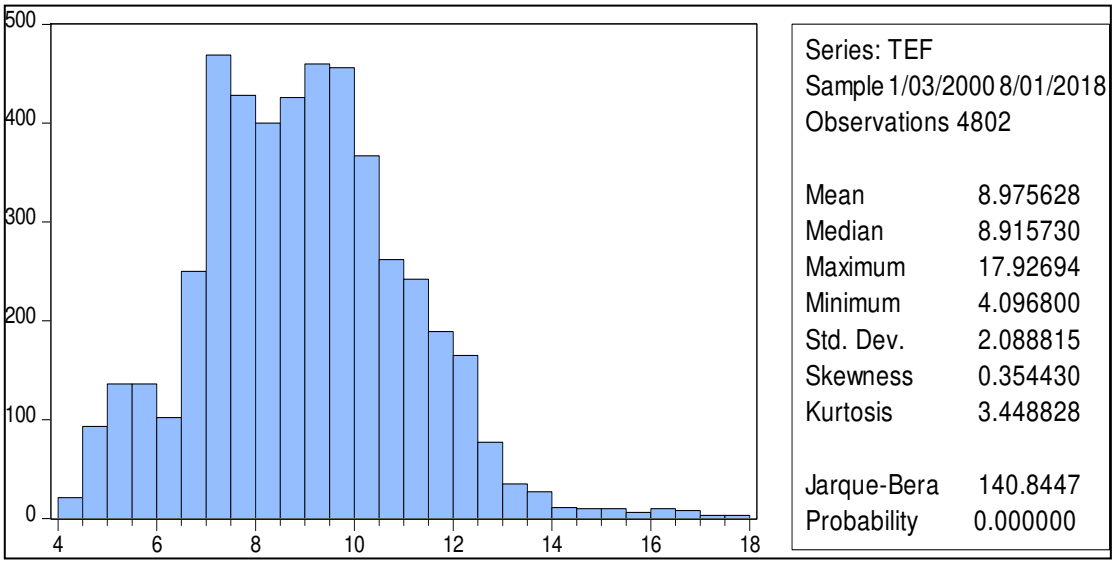

Figura 4.2 Histograma de frecuencia de la serie TEF
Fuente. Elaboración propia, empleando Eviews 10

Con las pruebas de RU, se comprobó que la serie original de TEF, no es estacionario. En los resultados del modelo de la figura 4.3 no se rechaza la hipótesis nula de que tenga RU por tanto la serie no es estacionaria.

Series: TEF Workfile: COTIZ_HISTORICOS TEF 03 E...

View | Proc | Object | Properties | Print | Name | Freeze | Sample | Genr | Sheet | Graph | Stat

Augmented Dickey-Fuller Unit Root Test on TEF

Null Hypothesis: TEF has a unit root
Exogenous: None
Lag Length: 3 (Automatic - based on SIC, maxlag=31)

		t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic		-1.094181	0.2488
Test critical values:	1% level	-2.565439	
	5% level	-1.940889	
	10% level	-1.616656	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation
Dependent Variable: D(TEF)
Method: Least Squares
Date: 05/20/20 Time: 14:31
Sample (adjusted): 1/07/2000 8/01/2018
Included observations: 4844 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
TEF(-1)	-0.000296	0.000270	-1.094181	0.2739
D(TEF(-1))	-0.016546	0.014356	-1.152563	0.2491
D(TEF(-2))	-0.052344	0.014319	-3.655577	0.0003
D(TEF(-3))	-0.047559	0.014321	-3.320837	0.0009

R-squared	0.005350	Mean dependent var	-0.001012
Adjusted R-squared	0.004734	S.D. dependent var	0.173828
S.E. of regression	0.173416	Akaike info criterion	-0.665417
Sum squared resid	145.5545	Schwarz criterion	-0.660062
Log likelihood	1615.640	Hannan-Quinn criter.	-0.663537
Durbin-Watson stat	1.998421		

Figura 4.3 Prueba de raíz unitaria de la serie original de TEF
Fuente. Elaboración propia, empleando Eviews 10

$$\mathrm{H}_0\text{: Raiz unitaria} = \text{serie es no estacionaria}$$

$$\mathrm{H}_1\text{: Raiz unitaria} \neq \text{serie es estacionaria.}$$

Partiendo del hecho de que la serie TEF no es estacionario, se procedió con diferenciar la serie hasta convertirlo en estacionaria para luego modelar el comportamiento de ese activo financiero: La serie que es estacionaria es aquella serie que resulta de la diferencia de los logaritmos y esto coincidió con la serie del rendimiento del activo financiero, entonces se generó los rendimientos del precio de cierre de las acciones de TEF de esta forma:

Primero se calculó los logaritmos para estabilizar la varianza, posteriormente se tomó las diferencias de esta variable transformada para estabilizar la media de esta forma se obtuvo una serie estacionaria. Con el software Eviews, se generó una nueva variable con el comando GENR dltef = dlog(tef). dlog es la diferencia de los logaritmos de la serie TEF.

Se graficó esta serie para analizar el comportamiento de estos rendimientos y verificó si cumplen un proceso estacionario, luego se graficó la

serie dltef para analizar el comportamiento de estos rendimientos para verificar si estos cumplen un proceso estacionario, pero esto es una prueba no formal.

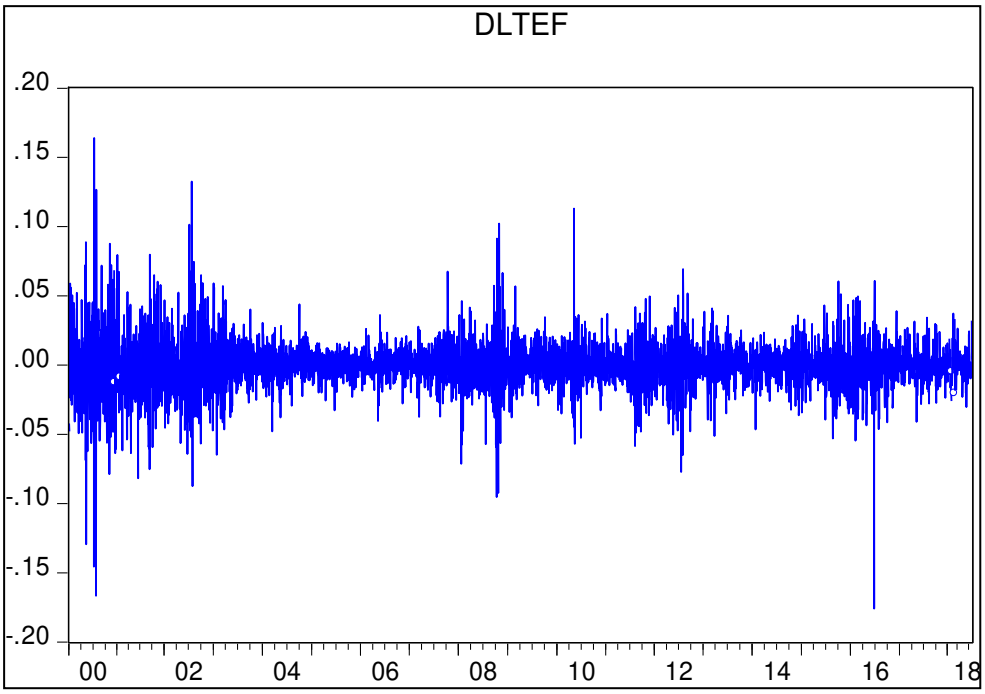

Figura 4.4 Retornos de la serie de TEF
Fuente. Elaboración propia, empleando Eviews 10

Se puede verificar gráficamente en la figura 4.4, que es un proceso estacionario pues la media es constante pero la varianza no parece ser estable a lo largo de todo el periodo.

Nuevamente se realizó la prueba formal de raíz unitaria como el test aumentado de Dickey fuller para comprobar que sea estacionaria y puede verificarse en la figura 4.5.

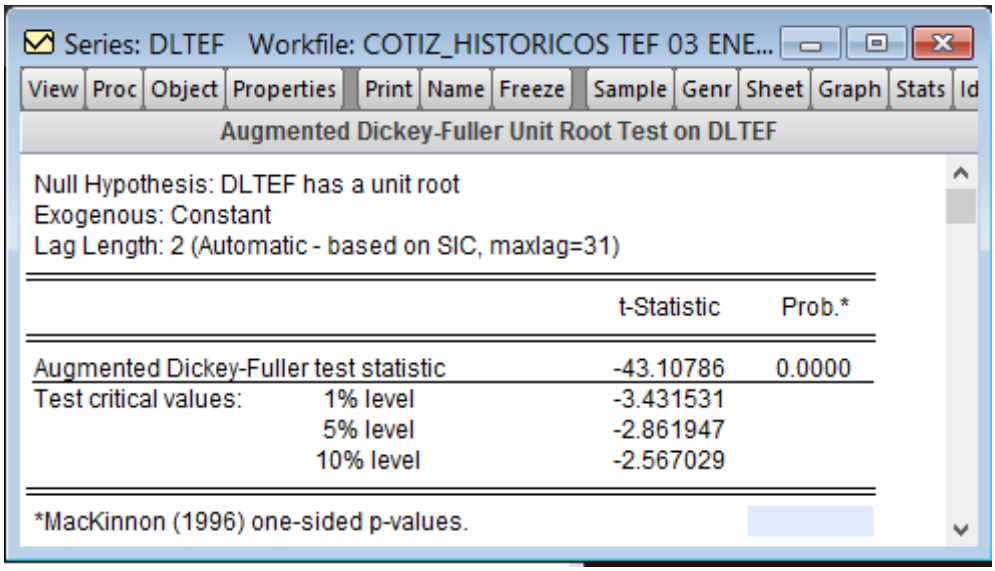

Figura 4.5 Prueba de raíz unitaria
Fuente. Elaboración propia, empleando Eviews 10

Las pruebas indican la presencia de raíz unitaria (RU) según la comparación entre el estadístico del test aumentado de Dickey-fuller y los distintos valores críticos de Mackinnon. En este caso se dice que una serie presenta RU si algunos de los valores críticos en valores absolutos de Mackinnon es mayor que el estadístico del test ADF en valores absolutos.

En este caso el valor del DFA es igual a |43.10786| es mayor que cualquiera de los valores críticos, al 1% = |3.431531|, 5% = |2.861947| y 10% = |2.567029|, lo que significa que la serie no presenta raíz unitaria y por tanto es una serie estacionaria En la figura 4.5 se aprecian los resultados pudiéndose comprobar con la primera diferencia que la seria es estacionaria. Asimismo, el P valor es menor que .05 y por tanto se rechaza la hipótesis nula de que tenga RU.

$$\mathrm{H}_0\text{: Raiz unitaria} = \text{serie es no estacionaria}$$

$$\mathrm{H}_1\text{: Raiz unitaria} \neq \text{serie es estacionaria}$$

Segundo, se efectuó la prueba de la serie de TEF de que no tenga ruido blanco, pues al haber ruido blanco existe un comportamiento aleatorio y por consiguiente la serie no tiene memoria, no está en función de su pasado y no se podría pronosticar con la metodología Box y Jenkins sino con otras técnicas clásicas, procesos estocásticos como el movimiento geométrico Browniano o las metodologías ARCH/GARCH: Para esto, se realizó la prueba de Ljung-Box de ruido blanco a través de un correlograma y dentro de esta la función de

autocorrelación simple y función de autocorrelación parcial, tal como se observa en la figura 4.6

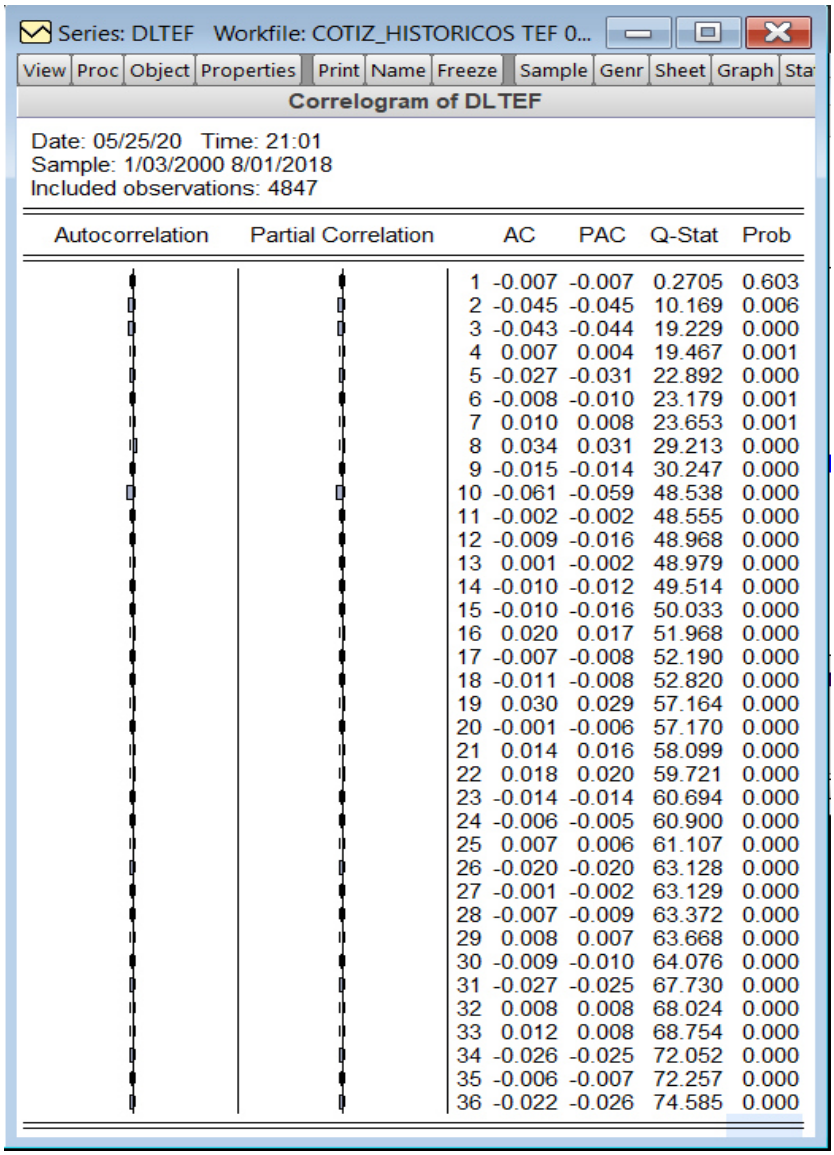

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
		1	-0.007	-0.007	0.2705	0.603
		2	-0.045	-0.045	10.169	0.006
		3	-0.043	-0.044	19.229	0.000
		4	0.007	0.004	19.467	0.001
		5	-0.027	-0.031	22.892	0.000
		6	-0.008	-0.010	23.179	0.001
		7	0.010	0.008	23.653	0.001
		8	0.034	0.031	29.213	0.000
		9	-0.015	-0.014	30.247	0.000
		10	-0.061	-0.059	48.538	0.000
		11	-0.002	-0.002	48.555	0.000
		12	-0.009	-0.016	48.968	0.000
		13	0.001	-0.002	48.979	0.000
		14	-0.010	-0.012	49.514	0.000
		15	-0.010	-0.016	50.033	0.000
		16	0.020	0.017	51.968	0.000
		17	-0.007	-0.008	52.190	0.000
		18	-0.011	-0.008	52.820	0.000
		19	0.030	0.029	57.164	0.000
		20	-0.001	-0.006	57.170	0.000
		21	0.014	0.016	58.099	0.000
		22	0.018	0.020	59.721	0.000
		23	-0.014	-0.014	60.694	0.000
		24	-0.006	-0.005	60.900	0.000
		25	0.007	0.006	61.107	0.000
		26	-0.020	-0.020	63.128	0.000
		27	-0.001	-0.002	63.129	0.000
		28	-0.007	-0.009	63.372	0.000
		29	0.008	0.007	63.668	0.000
		30	-0.009	-0.010	64.076	0.000
		31	-0.027	-0.025	67.730	0.000
		32	0.008	0.008	68.024	0.000
		33	0.012	0.008	68.754	0.000
		34	-0.026	-0.025	72.052	0.000
		35	-0.006	-0.007	72.257	0.000
		36	-0.022	-0.026	74.585	0.000

Figura 4.6 Prueba de ruido blanco de Ljung-Box
Fuente. Elaboración propia, empleando Eviews 10

$$\mathrm{H}_0\text{: Ruido blanco} = \text{serie no se puede pronosticar}$$

$$\mathrm{H}_1\text{: No ruido blanco} \neq \text{serie se puede pronosticar}$$

De los resultados del correlograma, se validó a través del P valor y la hipótesis nula de Ljung-Box que indican ruido blanco pues en la prueba conjunta el primer valor está por encima del 0.05, no tiene memoria, es una caminata aleatoria y se concluye que no se puede pronosticar con la metodología Box y Jenkins y por tanto no se puede continuar con sus pasos de estimación, validación y pronóstico.

4.1.2 Modelos de volatilidad condicional

En Jauregui (2017) se encontró que la varianza no es homocedastica o constante y los residuos no tuvieron ruido blanco, vale decir que la varianza es heterocedástica, se utilizó los modelos de la familia ARCH/GARCH. En consecuencia, se calculó los rendimientos de la serie TEF con el comando genr del Eviews: genr rtef = dlog(tef), la misma se visualiza en la figura 4.7.

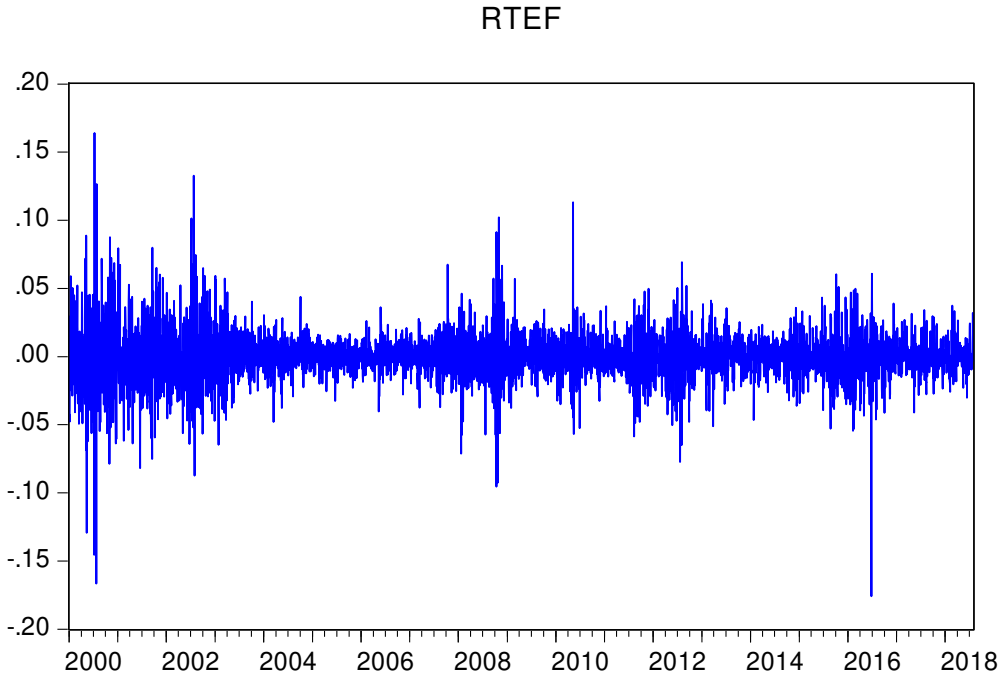

Figura 4.7 Rentabilidad de la serie TEF
Fuente. Elaboración propia, empleando Eviews 10

Se pudo observar en el gráfico anterior que hubo periodos de alta y baja volatilidad y que la varianza no era constante, pero esta observación es un método no formal, siendo necesario recurrir a un método formal a través de pruebas de hipótesis, para esto se procedió a construir un modelo de regresión, que incluye la constante que es la media del retorno con la siguiente ecuación: dlog(tef) c, tal como se aprecia en la figura 4.8

Equation: UNTITLED Workfile: COTIZ_HISTORICOS...

View | Proc | Object | Print | Name | Freeze | Estimate | Forecast | Stats | Resids

Dependent Variable: DLOG(TEF)
Method: Least Squares
Date: 05/13/20 Time: 19:10
Sample (adjusted): 1/04/2000 8/01/2018
Included observations: 4847 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.000121	0.000263	-0.458561	0.6466

R-squared	0.000000	Mean dependent var	-0.000121
Adjusted R-squared	0.000000	S.D. dependent var	0.018315
S.E. of regression	0.018315	Akaike info criterion	-5.161942
Sum squared resid	1.625611	Schwarz criterion	-5.160603
Log likelihood	12510.97	Hannan-Quinn criter.	-5.161472
Durbin-Watson stat	2.013844		

Figura 4.8 Modelo de regresión que incluye la constante
Fuente. Elaboración propia, empleando Eviews 10

Acto seguido con la figura 4.9, se realizó la prueba de heterocedasticidad para las siguientes hipótesis:

Hipótesis nula: H_0: σ^2 = homocedasticidad (la varianza es constante).

Hipótesis alternativa: H_1: $\sigma^2 \neq$ homocedasticidad (la varianza no es constante).

Equation: UNTITLED Workfile: COTIZ_HISTORICO...

View | Proc | Object | Print | Name | Freeze | Estimate | Forecast | Stats | Resids

Heteroskedasticity Test: ARCH

F-statistic	306.1425	Prob. F(1,4844)	0.0000
Obs*R-squared	288.0632	Prob. Chi-Square(1)	0.0000

Test Equation:
Dependent Variable: RESID^2
Method: Least Squares
Date: 05/13/20 Time: 20:17
Sample (adjusted): 1/05/2000 8/01/2018
Included observations: 4846 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.000253	1.64E-05	15.42551	0.0000
RESID^2(-1)	0.243772	0.013932	17.49693	0.0000

R-squared	0.059444	Mean dependent var	0.000335
Adjusted R-squared	0.059249	S.D. dependent var	0.001130
S.E. of regression	0.001096	Akaike info criterion	-10.79404
Sum squared resid	0.005818	Schwarz criterion	-10.79137
Log likelihood	26155.97	Hannan-Quinn criter.	-10.79310
F-statistic	306.1425	Durbin-Watson stat	2.018272
Prob(F-statistic)	0.000000		

Figura 4.9 Prueba de heterocedasticidad
Fuente. Elaboración propia, empleando Eviews 10

En este caso, como el p valor es menor a 0.05 y por tanto se rechaza la hipótesis nula de que la varianza es constante u homocedastica, entonces la

varianza es heterocedástica. Hay evidencia estadística de que la varianza de retornos de TEF no es constante.

También se comprobó con otra prueba formal, de que la serie tenga memoria o que no sean ruido blanco, a través de un análisis de correlograma de los residuos al cuadrado, las pruebas de Ljung-Box y el P valor, poder concluir que existe heterocedasticidad, tal como se parecía en la figura 4.10.

Hipótesis nula: H_0: residuos^2 = ruido blanco (la varianza es constante).

Hipótesis alternativa: H_1: residuos^2 ≠ ruido blanco (la varianza no es constante).

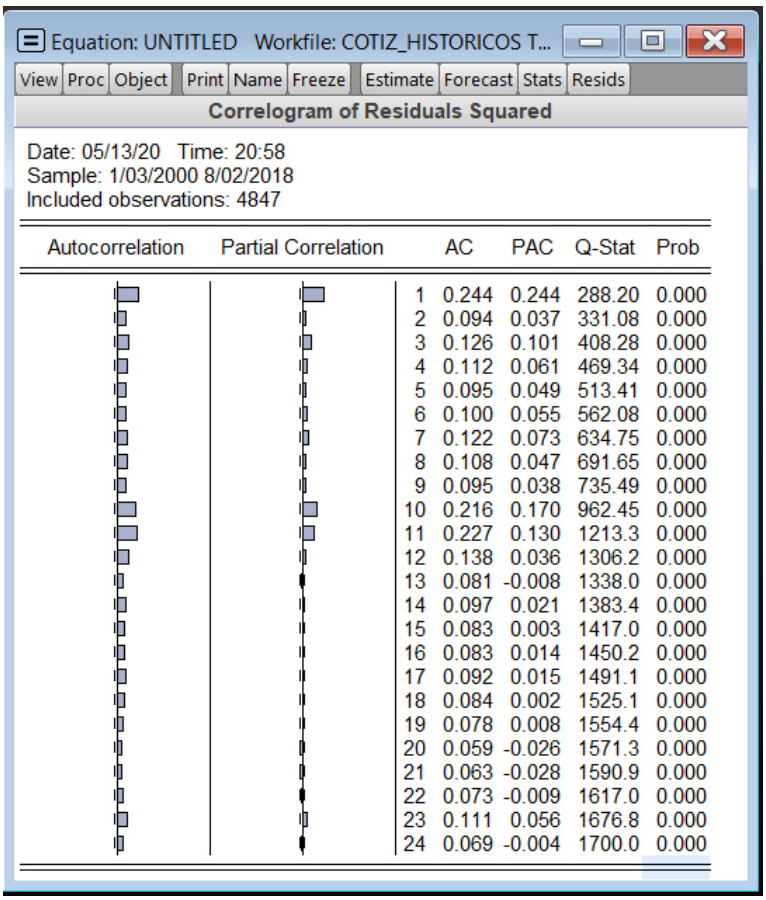

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob
		1	0.244	0.244	288.20	0.000
		2	0.094	0.037	331.08	0.000
		3	0.126	0.101	408.28	0.000
		4	0.112	0.061	469.34	0.000
		5	0.095	0.049	513.41	0.000
		6	0.100	0.055	562.08	0.000
		7	0.122	0.073	634.75	0.000
		8	0.108	0.047	691.65	0.000
		9	0.095	0.038	735.49	0.000
		10	0.216	0.170	962.45	0.000
		11	0.227	0.130	1213.3	0.000
		12	0.138	0.036	1306.2	0.000
		13	0.081	-0.008	1338.0	0.000
		14	0.097	0.021	1383.4	0.000
		15	0.083	0.003	1417.0	0.000
		16	0.083	0.014	1450.2	0.000
		17	0.092	0.015	1491.1	0.000
		18	0.084	0.002	1525.1	0.000
		19	0.078	0.008	1554.4	0.000
		20	0.059	-0.026	1571.3	0.000
		21	0.063	-0.028	1590.9	0.000
		22	0.073	-0.009	1617.0	0.000
		23	0.111	0.056	1676.8	0.000
		24	0.069	-0.004	1700.0	0.000

Figura 4.10 Análisis de correlograma para detectar ruido blanco
Fuente. Elaboración propia, empleando Eviews 10

En el modelo de la figura 4.10 se rechaza la hipótesis nula de que los residuos al cuadrado son ruido blanco, y que la varianza de los errores es heterocedástica.

Pero de acuerdo a la metodología Box y Jenkins, se necesita que los residuos sean ruido blanco, también es necesario que los residuos al cuadrado

sean ruido blanco, pero se comprobó con el correlograma contenida en la figura 4.10 que la varianza no es constante y por tanto se modeló con el método de estimación ARCH y un modelo ARCH(1) cuya estructura es que la varianza de los errores depende un periodo anterior de los errores al cuadrado y los resultados se aprecian en la figura 4.11 y muestran simultáneamente las ecuaciones de la media y la varianza y que explican el desenvolvimiento de los retornos de la serie TEF. En la ecuación de la varianza se observa que los residuos rezagados al cuadrado, son estadísticamente significativos pues están por debajo de 0.05 también es positivo dado que la varianza es positiva, también para garantizar la estabilidad, la sumatoria de los coeficientes del ARCH deben ser menores a 1.

Equation: PREBA_ARCH Workfile: COTIZ_HISTO...

View | Proc | Object | Print | Name | Freeze | Estimate | Forecast | Stats | Resids

Dependent Variable: DLOG(TEF)
Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)
Date: 05/27/20 Time: 20:14
Sample (adjusted): 1/04/2000 8/01/2018
Included observations: 4847 after adjustments
Convergence achieved after 13 iterations
Coefficient covariance computed using outer product of gradients
Presample variance: backcast (parameter = 0.7)
GARCH = C(2) + C(3)*RESID(-1)^2

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	-5.84E-05	0.000204	-0.285841	0.7750
Variance Equation				
C	0.000227	2.66E-06	85.28499	0.0000
RESID(-1)^2	0.364331	0.014093	25.85144	0.0000

R-squared	-0.000012	Mean dependent var	-0.000121
Adjusted R-squared	-0.000012	S.D. dependent var	0.018315
S.E. of regression	0.018316	Akaike info criterion	-5.269724
Sum squared resid	1.625630	Schwarz criterion	-5.265710
Log likelihood	12774.18	Hannan-Quinn criter.	-5.268315
Durbin-Watson stat	2.013821		

Figura 4.11 Resultados del modelo Arch
Fuente. Elaboración propia, empleando Eviews 10

Luego del modelamiento del paso anterior, se volvió a realizar la prueba de heterocedasticidad para la corrección y cuyo resultado es la obtención de una varianza constante solo con un ARCH(1) tal como se muestra en la figura 4.12.

Equation: PREBA_ARCH Workfile: COTIZ_HISTO...

View | Proc | Object | Print | Name | Freeze | Estimate | Forecast | Stats | Resids

Heteroskedasticity Test: ARCH

F-statistic	0.602249	Prob. F(1,4844)	0.4378
Obs*R-squared	0.602423	Prob. Chi-Square(1)	0.4377

Test Equation:
Dependent Variable: WGT_RESID^2
Method: Least Squares
Date: 05/27/20 Time: 21:02
Sample (adjusted): 1/05/2000 8/01/2018
Included observations: 4846 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	1.010822	0.047710	21.18689	0.0000
WGT_RESID^2(-1)	-0.011149	0.014367	-0.776047	0.4378

R-squared	0.000124	Mean dependent var	0.999670
Adjusted R-squared	-0.000082	S.D. dependent var	3.166877
S.E. of regression	3.167007	Akaike info criterion	5.143864
Sum squared resid	48585.00	Schwarz criterion	5.146541
Log likelihood	-12461.58	Hannan-Quinn criter.	5.144803
F-statistic	0.602249	Durbin-Watson stat	1.998838
Prob(F-statistic)	0.437759		

Figura 4.12 Resultados de la prueba Arch para la varianza constante
Fuente. Elaboración propia, empleando Eviews 10

Una vez superado esta prueba, se realizó el correlograma de los residuos al cuadrado para comprobar la presencia de ruido blanco y verificar la corrección de los problemas de acuerdo a la figura 4.13 y se comprobó que no había ruido blanco.

Equation: VERIF_RESDC Workfile: COTIZ_HISTORI...

View | Proc | Object | Print | Name | Freeze | Estimate | Forecast | Stats | Resids

Correlogram of Standardized Residuals Squared

Date: 05/27/20 Time: 21:52
Sample: 1/03/2000 8/01/2018
Included observations: 4847

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
		1	-0.011	-0.011	0.6029	0.437
		2	0.054	0.054	14.630	0.001
		3	0.096	0.097	58.982	0.000
		4	0.088	0.089	96.651	0.000
		5	0.063	0.058	116.12	0.000
		6	0.065	0.051	136.64	0.000
		7	0.098	0.080	183.01	0.000
		8	0.072	0.056	208.47	0.000
		9	0.069	0.047	231.44	0.000
		10	0.077	0.050	260.48	0.000
		11	0.225	0.203	506.50	0.000
		12	0.053	0.040	520.01	0.000
		13	0.060	0.022	537.55	0.000
		14	0.051	-0.005	550.35	0.000
		15	0.080	0.028	581.68	0.000
		16	0.051	0.009	594.36	0.000
		17	0.066	0.023	615.88	0.000
		18	0.052	-0.003	629.04	0.000
		19	0.073	0.026	655.13	0.000
		20	0.031	-0.016	659.75	0.000
		21	0.059	0.006	676.43	0.000
		22	0.069	-0.005	699.70	0.000
		23	0.084	0.047	733.98	0.000
		24	0.049	0.015	745.82	0.000
		25	0.055	0.021	760.64	0.000
		26	0.075	0.029	788.41	0.000
		27	0.032	-0.004	793.51	0.000
		28	0.050	0.004	805.60	0.000
		29	0.106	0.073	860.41	0.000
		30	0.032	-0.008	865.33	0.000
		31	0.041	0.009	873.65	0.000
		32	0.052	0.005	887.04	0.000
		33	0.053	0.009	900.75	0.000
		34	0.042	-0.012	909.26	0.000
		35	0.052	0.011	922.35	0.000
		36	0.043	-0.004	931.53	0.000

*Probabilities may not be valid for this equation specification.

Figura 4.13 Correlograma de los residuos al cuadrado
Fuente. Elaboración propia, empleando Eviews 10

Como en el correlograma de los residuos al cuadrado no se tuvieron ruido blanco, para la corrección se incluyó un GARCH(1), los resultados del modelo en la figura 4.14 muestran en la ecuación de las varianza que los coeficientes son estadísticamente significativos y que la sumatoria de estas mismas es menor a 1y se llama persistencia de los choque aleatorios y entre más se acerque a 1 los choques son persistentes.

Equation: VERIF_RESDC Workfile: COTIZ_HISTOR...

View | Proc | Object | Print | Name | Freeze | Estimate | Forecast | Stats | Resids

Dependent Variable: DLOG(TEF)
Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)
Date: 05/27/20 Time: 22:37
Sample (adjusted): 1/04/2000 8/01/2018
Included observations: 4847 after adjustments
Convergence achieved after 27 iterations
Coefficient covariance computed using outer product of gradients
Presample variance: backcast (parameter = 0.7)
GARCH = C(2) + C(3)*RESID(-1)^2 + C(4)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000261	0.000175	1.494366	0.1351
Variance Equation				
C	3.31E-06	4.02E-07	8.243982	0.0000
RESID(-1)^2	0.090208	0.004667	19.32889	0.0000
GARCH(-1)	0.901591	0.005344	168.7030	0.0000

R-squared	-0.000435	Mean dependent var	-0.000121
Adjusted R-squared	-0.000435	S.D. dependent var	0.018315
S.E. of regression	0.018319	Akaike info criterion	-5.544583
Sum squared resid	1.626319	Schwarz criterion	-5.539230
Log likelihood	13441.30	Hannan-Quinn criter.	-5.542704
Durbin-Watson stat	2.012968		

Figura 4.14 Estimación de la ecuación Arch(1) y Garch(1)
Fuente. Elaboración propia, empleando Eviews 10

Posteriormente con los resultados del correlograma de los residuos al cuadrado, se verificó que existiera ruido blanco, pues todos están por encima del 0.05 tal como se aprecia en la figura 4.15.

Equation: UNTITLED Workfile: COTIZ_HISTORICO...

View | Proc | Object | Print | Name | Freeze | Estimate | Forecast | Stats | Resids

Correlogram of Standardized Residuals Squared

Date: 05/29/20 Time: 23:20
Sample: 1/03/2000 8/01/2018
Included observations: 4847

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
		1	0.003	0.003	0.0557	0.813
		2	-0.014	-0.014	0.9959	0.608
		3	-0.003	-0.003	1.0286	0.794
		4	0.013	0.013	1.8668	0.760
		5	-0.001	-0.001	1.8722	0.867
		6	-0.015	-0.014	2.9260	0.818
		7	-0.012	-0.012	3.6612	0.818
		8	-0.012	-0.013	4.3664	0.823
		9	-0.005	-0.005	4.4965	0.876
		10	0.027	0.027	8.0740	0.622
		11	0.008	0.007	8.3518	0.681
		12	-0.006	-0.006	8.5532	0.741
		13	-0.002	-0.002	8.5690	0.805
		14	-0.007	-0.008	8.8100	0.843
		15	-0.014	-0.014	9.7330	0.836
		16	-0.001	-0.000	9.7352	0.880
		17	-0.004	-0.003	9.7970	0.912
		18	-0.007	-0.007	10.067	0.930
		19	-0.020	-0.019	12.019	0.885
		20	-0.014	-0.015	12.999	0.877
		21	-0.004	-0.005	13.071	0.906
		22	-0.003	-0.004	13.118	0.930
		23	0.019	0.019	14.790	0.902
		24	-0.006	-0.006	14.979	0.921

*Probabilities may not be valid for this equation specification.

Figura 4.15 Verificación de los residuos al cuadrado con GARCH
Fuente. Elaboración propia, empleando Eviews 10

Luego con los correlogramas de los residuos, se verificó que también existiera ruido blanco, pero la prueba conjunta mostró que no todos estaban por encima del 0.05 tal como se aprecia en la figura 4.16.

Equation: UNTITLED Workfile: COTIZ_HISTORICOS...

View | Proc | Object | Print | Name | Freeze | Estimate | Forecast | Stats | Resids

Correlogram of Standardized Residuals

Date: 05/29/20 Time: 23:45
Sample: 1/03/2000 8/01/2018
Included observations: 4847

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
		1	0.034	0.034	5.6014	0.018
		2	-0.013	-0.014	6.3812	0.041
		3	-0.013	-0.012	7.2138	0.065
		4	-0.002	-0.001	7.2352	0.124
		5	-0.018	-0.018	8.7756	0.118
		6	0.001	0.002	8.7860	0.186
		7	0.007	0.006	9.0030	0.252
		8	0.031	0.030	13.545	0.094
		9	-0.015	-0.017	14.707	0.099
		10	-0.036	-0.034	20.831	0.022
		11	0.000	0.003	20.831	0.035
		12	-0.012	-0.013	21.495	0.044
		13	0.010	0.011	22.002	0.055
		14	0.011	0.009	22.567	0.068
		15	-0.013	-0.015	23.330	0.077
		16	0.002	0.003	23.354	0.105
		17	0.006	0.007	23.527	0.133
		18	-0.007	-0.005	23.734	0.164
		19	0.008	0.008	24.050	0.194
		20	-0.002	-0.003	24.065	0.240
		21	0.006	0.005	24.239	0.282
		22	0.004	0.003	24.312	0.331
		23	-0.012	-0.010	24.957	0.352
		24	0.020	0.021	26.856	0.311

*Probabilities may not be valid for this equation specification.

Figura 4.16 Correlograma de residuos estandarizados
Fuente. Elaboración propia, empleando Eviews 10

En esta situación a fin de obtener ruido blanco se modeló la media. Cabe recordar que se presentan dos ecuaciones: la media y la varianza, la varianza se volvió homocedasticidad ósea constante, pero la ecuación de la media no tiene ruido blanco, pero fue corregida agregando la siguiente ecuación: dlog(tef) c ar(1) ar(2) ar(8) ma(1) ma(2), y los resultados fueron autorregresivos y de promedio móviles, los coeficientes fueron también significativos y la sumatoria de estos menor a 1. Asimismo, los coeficientes de la varianza también permanecieron significativos, los cuales se observan en la figura 4.17.

Equation: EQ_TESIS_HETR Workfile: COTIZ_HISTO...

View | Proc | Object | Print | Name | Freeze | Estimate | Forecast | Stats | Resids

Dependent Variable: DLOG(TEF)
Method: ML - ARCH
Date: 05/23/20 Time: 23:41
Sample (adjusted): 1/14/2000 8/01/2018
Included observations: 4839 after adjustments
Convergence achieved after 65 iterations
Coefficient covariance computed using outer product of gradients
MA Backcast: 1/12/2000 1/13/2000
Presample variance: backcast (parameter = 0.7)
GARCH = C(7) + C(8)*RESID(-1)^2 + C(9)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000269	0.000179	1.501751	0.1332
AR(1)	-0.709807	0.134009	-5.296725	0.0000
AR(2)	-0.662890	0.144257	-4.595212	0.0000
AR(8)	0.031394	0.012591	2.493439	0.0127
MA(1)	0.732414	0.131535	5.568216	0.0000
MA(2)	0.668382	0.143037	4.672801	0.0000
Variance Equation				
C	3.31E-06	4.01E-07	8.252688	0.0000
RESID(-1)^2	0.090859	0.004945	18.37418	0.0000
GARCH(-1)	0.900953	0.005476	164.5144	0.0000

R-squared	0.000033	Mean dependent var	-0.000116
Adjusted R-squared	-0.001002	S.D. dependent var	0.018280
S.E. of regression	0.018289	Akaike info criterion	-5.547819
Sum squared resid	1.616585	Schwarz criterion	-5.535759
Log likelihood	13431.95	Hannan-Quinn criter.	-5.543585
Durbin-Watson stat	2.061547		

Inverted AR Roots	.54	.33-.45i	.33+.45i	-.23-.71i
	-.23+.71i	-.42-.61i	-.42+.61i	-.61
Inverted MA Roots	-.37+.73i	-.37-.73i		

Figura 4.17 Ecuación Garch para modelar la media
Fuente. Modelo Elaboración propia, empleando Eviews 10

Luego se volvieron a validar resultados de los correlogramas para los residuos, y se observó que presentó ruido blanco pues el P valor de la prueba conjunta está por encima del 0.05, corrigiéndose el problema de la media, los cuales muestran en la figura 4.18. En concordancia con esto, los modelos ARIMA siempre sus residuos y residuos al cuadrado deben ser ruido blanco, pues deber anularse toda la autocorrelación que podría haber entre sus residuos y que no tengan memoria.

Equation: EQ_TESIS_HETR Workfile: COTIZ_HISTO...

View | Proc | Object | Print | Name | Freeze | Estimate | Forecast | Stats | Resids

Correlogram of Standardized Residuals

Date: 05/30/20 Time: 15:20
Sample: 1/03/2000 8/01/2018
Included observations: 4839
Q-statistic probabilities adjusted for 5 ARMA terms

Autocorrelation	Partial Correlation		AC	PAC	Q-Stat	Prob*
		1	0.014	0.014	0.8917	
		2	-0.003	-0.003	0.9255	
		3	-0.006	-0.006	1.1235	
		4	-0.012	-0.012	1.8388	
		5	-0.015	-0.014	2.8911	
		6	0.007	0.007	3.1368	0.077
		7	0.001	0.000	3.1407	0.208
		8	0.004	0.004	3.2367	0.357
		9	0.008	0.007	3.5200	0.475
		10	-0.034	-0.034	9.0476	0.107
		11	-0.015	-0.014	10.154	0.118
		12	-0.002	-0.001	10.167	0.179
		13	0.012	0.012	10.900	0.207
		14	0.001	-0.000	10.902	0.282
		15	-0.008	-0.009	11.216	0.341
		16	0.005	0.006	11.350	0.414
		17	0.001	0.002	11.361	0.498
		18	-0.005	-0.005	11.500	0.569
		19	0.010	0.010	11.960	0.610
		20	-0.003	-0.004	11.996	0.679
		21	0.005	0.004	12.105	0.737
		22	0.005	0.005	12.244	0.785
		23	-0.011	-0.010	12.824	0.802
		24	0.019	0.020	14.638	0.745
		25	0.008	0.007	14.955	0.779
		26	-0.014	-0.014	15.905	0.775
		27	-0.007	-0.006	16.118	0.810
		28	-0.008	-0.008	16.433	0.836
		29	-0.001	0.001	16.435	0.872
		30	-0.022	-0.023	18.851	0.804
		31	-0.016	-0.016	20.103	0.787
		32	0.007	0.008	20.373	0.815
		33	0.010	0.009	20.876	0.830
		34	-0.029	-0.029	25.045	0.676
		35	-0.007	-0.007	25.313	0.710
		36	-0.012	-0.012	26.030	0.720

*Probabilities may not be valid for this equation specification.

Figura 4.18 Correlograma de los residuos con ruido blanco
Fuente. Modelo Elaboración propia, empleando Eviews 10

Con todos estos resultados el siguiente paso fue estimar la rentabilidad y volatilidad

4.1.3 El impacto de las noticias

Cuando las noticias impactan en los mercados financieros, los movimientos a la baja son seguidos por volatilidades más grandes debido a malas noticias, que cuando se presentan noticias positivas, los movimientos al alza no son de similar magnitud, es decir la volatilidad tiene un comportamiento asimétrico y el modelo TGarch capturó esta asimetría, siguiendo la ecuación

dlog(tef) c ar(1) ar(2) ar(8) ma(1) ma(2) observada en la figura 4.16. Los resultados que se aprecian en la figura 4.19 muestran que la ecuación RESID (-1)^2*(RESID (-1)<0) presenta el impacto de noticias negativas en la varianza condicional. Se observó que su coeficiente es igual a 0,095395, por consiguiente, estadísticamente es significativo y mayor que 0 y, se concluye que el efecto del apalancamiento está latente y a tener coeficiente diferente de cero, y hay asimétrica en la curva por efecto de las noticias.

Equation: UNTITLED Workfile: COTIZ_HISTORICOS TE...

View | Proc | Object | Print | Name | Freeze | Estimate | Forecast | Stats | Resids

Dependent Variable: DLOG(TEF)
Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)
Date: 06/01/20 Time: 19:47
Sample (adjusted): 1/14/2000 8/01/2018
Included observations: 4839 after adjustments
Convergence achieved after 61 iterations
Coefficient covariance computed using outer product of gradients
MA Backcast: 1/12/2000 1/13/2000
Presample variance: backcast (parameter = 0.7)
GARCH = C(7) + C(8)*RESID(-1)^2 + C(9)*RESID(-1)^2*(RESID(-1)<0)
+ C(10)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C	-6.27E-05	0.000192	-0.326368	0.7441
AR(1)	-0.562885	0.167098	-3.368592	0.0008
AR(2)	-0.559819	0.170672	-3.280081	0.0010
AR(8)	0.036699	0.013394	2.739976	0.0061
MA(1)	0.589171	0.166553	3.537445	0.0004
MA(2)	0.559164	0.170371	3.282030	0.0010
Variance Equation				
C	3.47E-06	3.75E-07	9.261739	0.0000
RESID(-1)^2	0.033989	0.005149	6.601490	0.0000
RESID(-1)^2*(RESID(-1)<0)	0.095395	0.009116	10.46464	0.0000
GARCH(-1)	0.908299	0.005661	160.4581	0.0000

R-squared	0.001093	Mean dependent var	-0.000116
Adjusted R-squared	0.000060	S.D. dependent var	0.018280
S.E. of regression	0.018279	Akaike info criterion	-5.560633
Sum squared resid	1.614871	Schwarz criterion	-5.547233
Log likelihood	13463.95	Hannan-Quinn criter.	-5.555929
Durbin-Watson stat	2.069923		

Inverted AR Roots	.56	.35-.47i	.35+.47i	-.16+.74i
	-.16-.74i	-.44-.57i	-.44+.57i	-.63
Inverted MA Roots	-.29-.69i	-.29+.69i		

Figura 4.19 Modelo Tgarch que captura impacto de las noticias
Fuente. Modelo Elaboración propia, empleando Eviews 10

4.2 Interpretación de resultados

Dentro de las características que la volatilidad tiene, el efecto de periodos de alta y baja volatilidad como por ejemplo los agrupamientos o clusters se tuvo en cuenta el tipo de distribución de probabilidad que presentó esta serie de rendimientos de acuerdo a la figura 4.20:

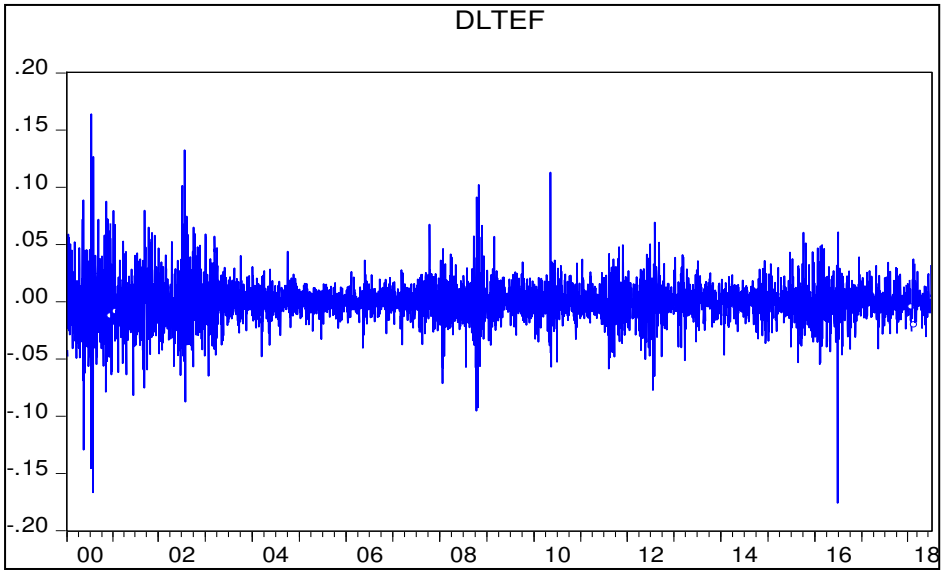

Figura 4.20 Agrupamiento de volatilidad
Fuente. Elaboración propia, empleando Eviews 10

- Los retornos en ciertos periodos tiene valores extremos y por lo tanto la serie deja de comportarse como si fuera una distribución normal, pasando a convertirse en una distribución t-student.
- La volatilidad o incertidumbre tiende a agruparse, por ejemplo, durante la crisis del 2008 fecha en que hubo mucha volatilidad, o sea, en ciertos periodos la volatilidad se agrupó. Este fenómeno también se conoce como clusters.

Con la figura 4.21, se tuvo en cuenta el tipo de distribución que presentó la serie de rendimientos graficándose el histograma.

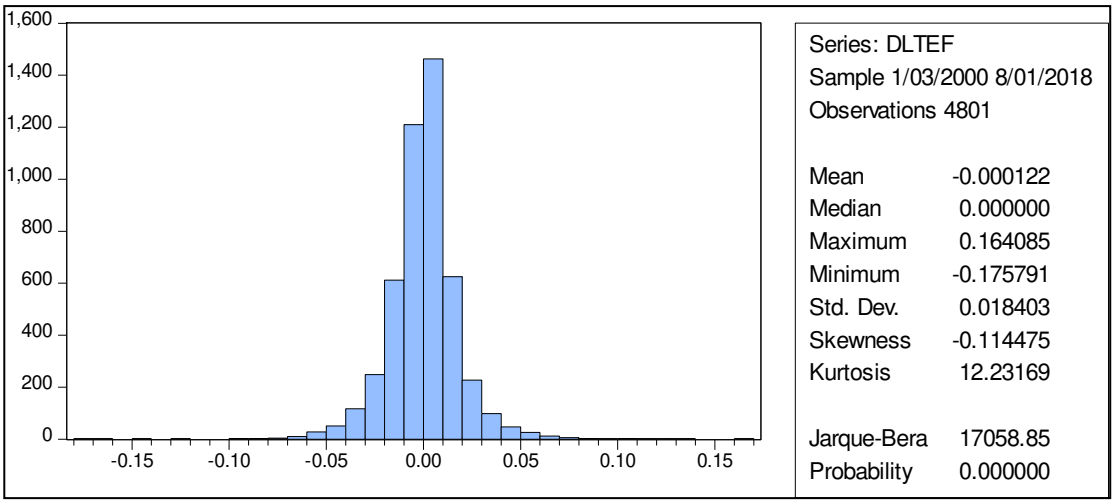

Figura 4.21 Histograma de los rendimientos
Fuente. Elaboración propia, empleando Eviews 10

Se observó un comportamiento que presenta curtosis muy altas lo que significa que esta distribución sigue una distribución leptocúrtica que son

distribuciones donde la concentración de los datos con respecto a los valores centrales o al valor esperado de estos rendimientos, es muy alto y se observó que los efectos en las colas son pequeñas o angostas que son las características de una distribución leptocúrtica.

4.2.1 Estimación

Primero se estimó la rentabilidad y volatilidad del precio de las acciones de TEF, no fue necesario agrandar el rango de la muestra, pero sirve para observar los estadísticos de error.

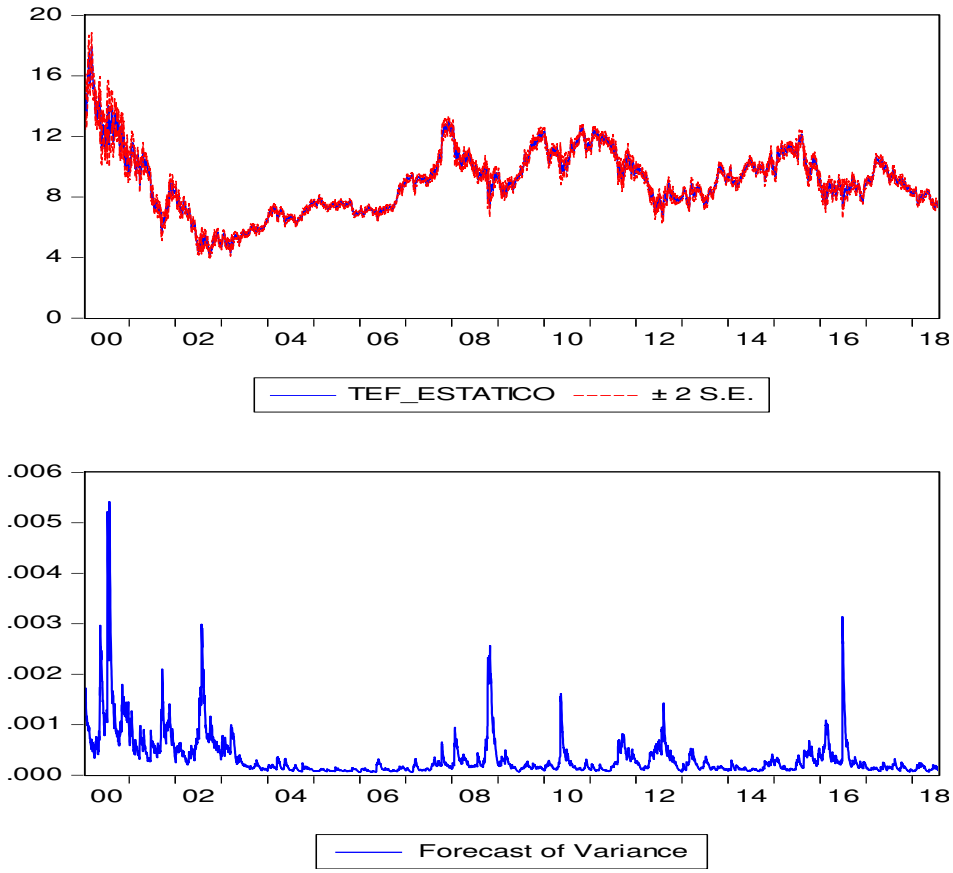

Figura 4.22 Estimación de la rentabilidad y volatilidad de TEF
Fuente. Elaboración propia, empleando Eviews 10

Los resultados muestran el comportamiento del precio (TEF_ESTATICO) de las acciones de TEF y en la parte inferior de la figura 4.22, su volatilidad (Forecast of variance), en esta última se observó que hubo periodos de alta y baja volatilidad o conocida como aglomeración de volatilidad.

Posteriormente se pronosticó un periodo el precio de la acción de TEF y su volatilidad, para lo cual se amplió el rango de la muestra de 4848 a 4849 observaciones, vale decir se pronosticó para el 02/02/18, y cuyos resultados se

muestran del precio de la acción de TEF y su volatilidad, se muestran en la figura 4.23.

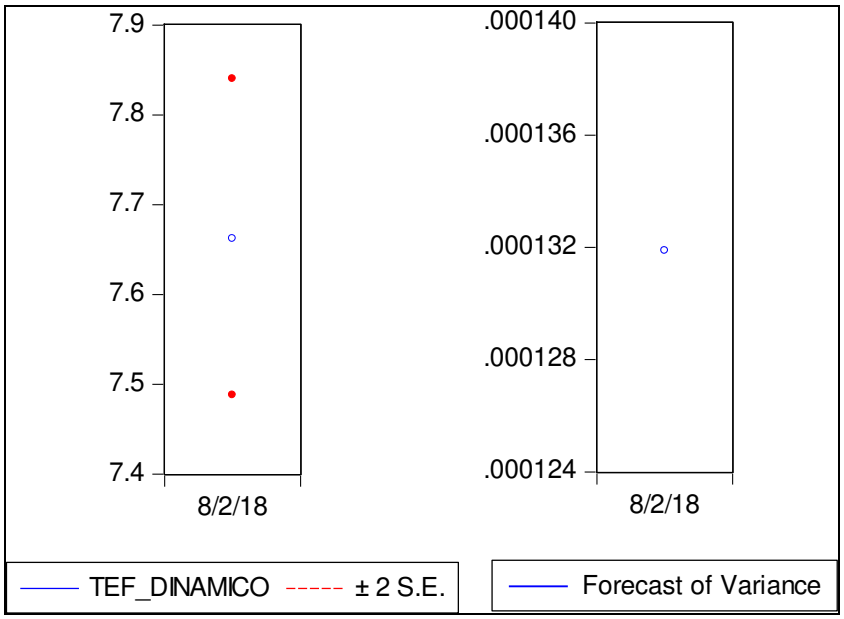

Figura 4.23 *Pronóstico del precio y la volatilidad TEF, para el día 2/8/2018*
Fuente. Elaboración propia, empleando Eviews 10

4.2.2 Errores de pronóstico (residuos)

Para pronosticar series de tiempo, un concepto fundamental es el error de pronóstico (residuo), Esta perturbación o choque aleatorio es la diferencia entre el valor observado y el valor pronosticado y tiene la siguiente expresión: $e_t = y_t - \hat{y}_t$.

En el anexo 1 se podrá encontrar resultados fueran de muestra, es decir, el precio de cierre de TEF desde el 02 de agosto al 15 de agosto del 2018 y 10 pronósticos para 10 días útiles con las siguientes metodologías y técnicas: Garch, TGarch, Redes neuronales probabilísticas/Redes neuronales de regresión generalizada con NeuralTools, Redes neuronales con Risk Simulator y las técnicas de suavizamientos exponencial doble.

En el cuadro 4.3 se observan los resultados de cuatro técnicas de pronóstico dentro de muestra, de la serie original con 4,848 observaciones del precio de cierre de las cotizaciones diarias de TEF dentro del rango del 03 de enero del 2000 al 01 de agosto del 2018. Los pronósticos obtenidos dentro de muestra fueron los siguientes:

- Para los modelos Garch y TGarch, fueron obtenidos con el software econométrico Eviews 10.

- Para las redes neuronales fueron realizadas con el programa NeuralTools 7.6 de Palisade que utiliza redes neuronales en Microsoft Excel, el tipo de red usado fue la Red PN/GRN (Redes neuronales probabilísticas/Redes neuronales de regresión generalizada), y con una variable dependiente numérica, entrena una red numeral de regresión generalizada y la precisión de su error es comparable a las redes MLF (Redes multinivel siempre hacia adelante).
- Para las técnicas de suavizamientos exponencial doble esta fue seleccionada automáticamente por el software Risk Simulator. Este software pronóstico los datos de las series temporales al descomponerlos en líneas de base, tendencia y componentes estacional, pero al existir ocho técnicas, el mismo Risk Simulator eligió la mejor técnica considerando el menor estadístico de error en este caso, el menor RMSE.

En los resultados fuera de muestra, fueron utilizados 5 técnicas con los resultados de las diferencias de 10 días reales y pronosticadas a partir del 02/08/18 al 15/08/18, Los pronósticos obtenidos fuera de muestra fueron los siguientes:

- Para las redes neuronales con NeuralTools, fueron realizadas con el programa NeuralTools 7.6 de Palisade.
- Para las redes neuronales con Risk Simulator, fueron realizadas con el programa Risk Simulator para Excel.
- Para el modelo Garch, fue desarrollado con el software econométrico Eviews 10.
- Para las técnicas de suavizamientos exponencial doble esta fue seleccionada automáticamente por el software Risk Simulator.
- Para el modelo TGarch, fue desarrollado con el software econométrico Eviews 10.

Las técnicas de pronóstico fueron evaluadas con las siguientes estadísticas de error: **RMSE** (Raíz de error cuadrático medio), **MAD** (Desviación media absoluta), **MAPE** (Error Porcentual Absoluto Medio), **MPE** (Error porcentual medio) y **U-THEIL** (Coeficiente de desigualdad de Theil) y están contenidas en el cuadro adjunto:

Cuadro 4.1 **Errores de pronóstico**

		Errores de pronóstico				
	Técnicas y modelos	**RMSE**	**MAD**	**MAPE**	**MPE**	**U-THEIL**
Dentro de muestra	Redes Neuronales con NeuralTools	0.1213	0.0796	0.879%	-0.004%	0.0066
	TGarch	0.1733	0.1104	1.230%	-0.064%	0.0094
	Garch	0.1737	0.1108	1.233%	-0.065%	0.0094
	Suavizado Exponencial Doble	0.1740	0.1109	1.233%	-0.037%	1.0000
Fuera de muestra	Redes Neuronales con NeuralTools	0.0420	0.0351	0.465%	-0.025%	0.0055
	Redes Neuronales con Risk Simulator	0.0420	0.0351	0.465%	-0.025%	0.0055
	Garch	0.0466	0.1296	1.736%	-1.736%	0.0214
	Suavizado Exponencial Doble	0.1488	0.1148	1.538%	-1.538%	0.0193
	TGarch	0.1510	0.1172	1.569%	-1.569%	0.0196

Fuente. Elaboración propia

Cuando se interpretan los resultados dentro de muestra, en general se prefiere el RMSE por que la diferencia al elevarse al cuadrado, se magnifica los valores al tener desviaciones grandes dando como resultado en promedio, cuanto se desvía en unidades y son las Redes neuronales calculadas con NeuralTools, que tiene un valor de 0.1213 siendo es más pequeño o cercano a cero. Por otra parte, el MAPE es utilizado para validar la exactitud en porcentajes pues al estar relativizada por el valor real hace que se pierdan las unidades y nuevamente Redes neuronales calculadas con NeuralTools obtiene un valor promedio de 0.879% siendo la más pequeñas con respecto a las otras técnicas y modelos también obtiene buenos resultados en el MAD y en la U-Theil, sin embargo, los modelos TGarch (-0.064%) y Garch (-0.065%) en MPE obtuvieron los valores más negativos.

Los resultados fuera de muestra, confirman que los resultados obtenidos con las Redes neuronales con NeuralTools y Risk Simulator son similares y son las más pequeñas, pero en el MPE el modelo Garch tiene el valor más negativo -1.736%.

En el anexo 2 se podrá encontrar el promedio de los errores al cuadrado y raíz del error cuadrático medio de los cinco modelos pronosticados, en el anexo

3 se encuentran los MAD (desviación absoluta media) y MAPE (desviación absoluta porcentual media) y en el anexo 4 el MPE (error porcentual medio) todas estas corresponden a los resultados fuera de muestra.

Al pronosticar series de tiempo, se presentan problemas cuando se basan en los pronósticos puntuales por lo que se recurre al pronóstico por intervalo de probabilidad, para conocer entre que valores de ese intervalo podría estar una variable.

4.3 Pruebas de Hipótesis

4.3.1 Hipótesis general

Mediante la aplicación de modelos condicionados a su pasado, se pronosticarán adecuadamente los precios de las acciones de Telefónica cotizadas en la New York Stock Exchange (NYSE)

4.3.2 Hipótesis específicas (HE)

HE1: La diferenciación de los precios de cierre influye directamente en la media de los retornos de las acciones de Telefónica S.A.

Con información desde el 03 de enero del 2000 al 01 de agosto del 2018, se demostró con la metodología Box y Jenkins que la rentabilidad o valor esperado de la serie financiera de TEF, ya diferenciada y estacionaria, era igual a 0 (cero), es decir su media es constante a lo largo del tiempo y se comprobó comparando dos muestras independientes para lo cual se tomó 522 retornos del periodo 2005 al 2006 tiempo en que hubo baja volatilidad en comparación con otros 522 observaciones del periodo 2007-2008 en que existió alta volatilidad. Los resultados fueron obtenidos con el paquete estadístico SPSS 25; en el cuadro 4.1 se obtuvieron los estadísticos de grupo y en el cuadro 4.2 se muestran los resultados de la comparación de medias.

Cuadro 4.2 **Estadísticas de grupo**

	años	N	Media	Desviación estándar	Media de error estándar
Retornos	2005-2006	522	,000286	,0088012	,0003852
	2007-2008	522	,000090	,0186111	,0008145

Fuente. Elaboración con el SPSS 25

Cuadro 4.3 **Pruebas de igualdad de medias y de Levene de igualdad de varianzas**

Prueba de muestras independientes

		Prueba de Levene de igualdad de varianzas		prueba t para la igualdad de medias						
		F	Sig.	t	gl	Sig. (bilateral)	Diferencia de medias	Diferencia de error estándar	95% de intervalo de confianza de la diferencia	
									Inferior	Superior
Retorno	Se asumen varianzas iguales	80.291	0.000	0.217	1042	0.828	0.000195	0.00090	-0.00157	0.00196
	No se asumen varianzas iguales			0.217	742.929	0.828	0.000195	0.00090	-0.00157	0.00196

Fuente. Elaboración con el SPSS 25

A continuación, se presentan las siguientes pruebas estadísticas**:**

4.3.2.1 Prueba de hipótesis para la igualdad de medias

H_o: Las medias de los periodos 2005-2006 y 2007-2008 son iguales

H_1: Las medias de los periodos 2005-2006 y 2007-2008 no son iguales

Nivel de significancia

Alfa = 5% o 0.05

Estadístico de prueba

Prueba t para 2 muestras independientes

P valor = 0.828

La prueba demuestra una significancia bilateral de 0.828 >0.05 y, por tanto, no se rechaza la hipótesis de igualdad de medias y, se acepta la hipótesis nula de que hay igualdad de medias

Toma de decisiones

Las medias de los grupos a comparar, no son diferentes

Interpretación

Las medias de los dos grupos son constantes.

HE2 El nivel de volatilidad influye directamente en la varianza de los retornos de las acciones de Telefónica S.A.

Con las mismas dos muestras independientes de 522 retornos del periodo 2005 al 2006 tiempo en que hubo baja volatilidad y 522 observaciones del periodo 2007-2008 en que existió gran volatilidad, se demostró que la varianza no era constante u homocedastica, sino heterocedástica precisamente porque hubo periodos de alta volatilidad en los retornos impactando en la varianza y que no pudo ser modelado con la metodología Box y Jenkins, pero si con los modelos de heterocedasticidad condicional. En el cuadro 4.2 se muestran los resultados de la prueba de Levene para la igualdad de varianzas.

4.3.2.2 Prueba de hipótesis para la igualdad de varianza

H_o: Las varianzas de los periodos 2005-2006 y 2007-2008 son homocedásticas o no son diferentes

H_1: Las varianzas de los periodos 2005-2006 y 2007-2008 son heterocedásticas o son diferentes

Nivel de significancia

Alfa = 5% o 0.05

Estadístico de prueba

Test de Levene

P valor = 0.0000

Lectura del valor P: Con una probabilidad de error del 0.000 la varianza de los grupos a comparar son heterocedásticas o diferentes y por tanto, se rechaza la hipótesis nula de igualdad de varianzas.

Toma de decisiones

La varianza de los grupos a comparar no son homocedásticas o no son diferentes

Interpretación

La varianza de los dos grupos son heterocedásticas o son diferentes.

4.3.2.3 Prueba de normalidad de Jarque-Bera para la asimetría y curtosis

Las variables aleatorias al tener una distribución normal, su simetría es igual a cero y su curtosis igual a tres, en el primer de los casos la distribución es simétrica y en el segundo mesocúrtica. Con la prueba de Jarque y Bera, se plantea que el tercer y cuarto momento alrededor de la media, no son iguales y cuyos resultados se muestran en la figura 4.24.

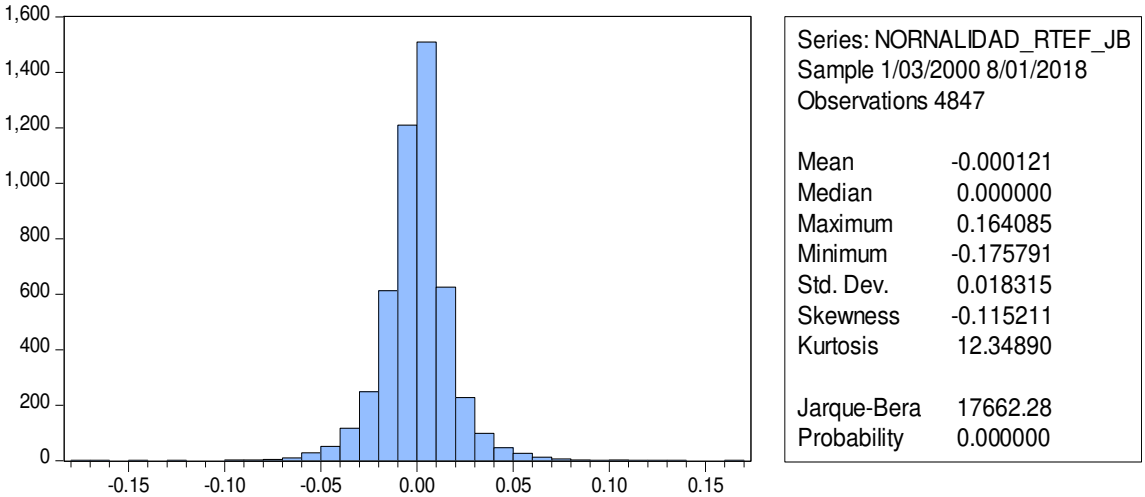

Figura 4.24 Resultados de la prueba de normalidad de Jarque-Bera
Fuente. Elaboración propia, empleando Eviews 10

La hipótesis a probar fue la siguiente:

H_0: La distribución de los errores es una distribución normal

H_1: La distribución de los errores no es una distribución normal

Nivel de significancia

Alfa = 5% o 0.05

Estadístico de prueba

Prueba de normalidad de Jarque-Bera

P valor = 0.0000

Lectura del valor P: Con una probabilidad de error del 0.000 la distribución de los errores no es una distribución normal.

Toma de decisiones

La distribución de los errores no es una distribución normal.

Interpretación

La simetría no es igual cero y la curtosis es diferente de 3 y por consiguiente a distribución de los errores no es una distribución normal.

O también

HE3 Los niveles de noticias influyen directamente en el tipo de asimetría de la volatilidad de los retornos de las acciones de Telefónica S.A.

H_0: s=0

H_1: s≠0

Datos: n=4847 Asimetría=-0.115211 Curtosis=12.34890

Nivel de significancia

(alfa) a = 5% o 0.05. Entonces Chi α/2 = 5.991

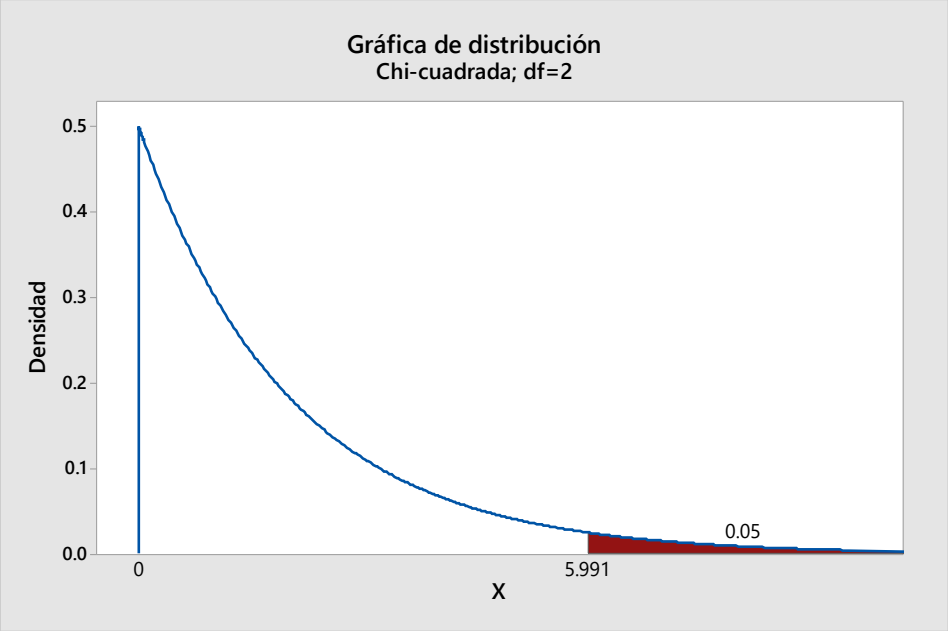

Figura 4.25 Gráfico de distribución Chi-cuadrada
Fuente. Elaboración propia, empleando Minitab 18

Estadístico de prueba

$$JB=N\left(\frac{S^2}{6}+\frac{(k-3)^2}{24}\right)\sim\chi^2_{gl} \quad =4847\left(\frac{-0.115211^2}{6}+\frac{(12.34890-3)^2}{24}\right)=17662.28$$

		P valor
Valor crítico	5.991465	0.05
Jarque-Bera	17662.27	0.00

Decisión: Como JB = 17662.28 > 5.991 se rechaza la Ho, la distribución de los errores no es una distribución normal y por tanto es asimétrica a la izquierda con un valor de -0.115211. Asimismo, su P valor es 0.00 < 0.05, se rechaza la Ho.

HE4 Los valores extremos de los retornos influyen directamente en el tipo curtosis de la volatilidad de las acciones de Telefónica S.A.

H_0: k=3

H_1: k≠3

a Datos: n=4847 Asimetría=-0.115211 Curtosis=12.34890

b Nivel de significancia (alfa) a = 5% o 0.05. Entonces Chi α/2 = 5.991

c Estadístico de prueba

$$JB=N\left(\frac{S^2}{6}+\frac{(k-3)^2}{24}\right)\sim\chi^2_{gl} \quad =4847\left(\frac{-0.115211^2}{6}+\frac{(12.34890-3)^2}{24}\right)=17662.28$$

		P valor
Valor crítico	5.991465	0.05
Jarque-Bera	17662.27	0.00

d Decisión: Como JB = 17662.28 > 5.991 se rechaza la Ho, la distribución de los errores no es una distribución normal y por tanto es leptocúrtica con un valor de 12.34890. Asimismo, su P valor es 0.00 < 0.05, se rechaza la Ho.

4.4 Presentación de resultados

4.4.1 Con referencia a la diferenciación de los precios de cierre que influyen directamente en la media de los retornos

En los resultados se observó que los precios de cierre de las acciones de TEF no eran estacionarias y se tuvieron que realizarse diferencias logarítmicas para convertirlas en estacionaria tal como se encontró en los siguientes trabajos:

Villalba y Flores (2014) al analizar el comportamiento de la volatilidad del índice de precios y cotizaciones (IPC) del mercado bursátil mexicano para estimar la tendencia de los precios de las acciones que la componen, que verificaron la importancia de la estacionariedad de dichas series que fueron trasformadas cuando aplicaron una diferencia logarítmica para convertirlos en rendimientos continuos y estacionarios.

Hossain, Kamruzzaman y Ali (2015), Utilizan series temporales en el nivel, en la primera diferencia, en la transformación logarítmica y para explorar los datos y que la trama de la serie de tiempo transformado de registro transgrede la tendencia original y no puede eliminar la variación irregular de la serie de datos. La serie transformada diferenciada muestra que la media es constante pero no la varianza.

Parody, Charris y García (2016), Con las series de “precios de cierre diario de las acciones del Banco de Colombia, Banco de Bogotá y Banco de Occidente, en el periodo de tiempo comprendido entre el 17 al 24 de julio de 2015”, calcularon los retornos diarios por cada banco a través de la diferenciación.

Tsakou (2016) en su tesis doctoral, calculó las rentabilidades de los índices bursátiles estadounidenses y europeos, r_t, calculando las diferencias de los precios log, $r_t = \ln (Pt/P_{t-1})$. Sus resultados mostraron que la media de los retornos es constante y alrededor de cero, pero la varianza cambia con el tiempo mostrando evidencia de agrupación de volatilidad.

4.4.2 Con referencia al nivel de volatilidad que influye directamente en la heteroscedasticidad de la varianza de los retornos

Se encontró que la varianza de los rendimientos de TEF a lo largo del tiempo, no fue homocedastica o constante, siendo imposible ser pronosticadas con la metodología Box y Jenkins. En este caso la varianza es heterocedástica, tal como se halló en las siguientes investigaciones:

Hossain, Kamruzzaman y Ali (2015) encuentran que las series de volumen de existencias diarios de Dhaka Stock Exchange (DSE). son heterocedásticas y la serie transformada diferenciada muestra que la media es constante pero no la varianza y agregan que, para seleccionar la mejor clase de modelo de volatilidad, se aplican modelos de clase de heteroscedasticidad (ARCH)

De Jesús, Vergara, y Díaz (2015) en su trabajo de investigación desarrollado, tuvo como objetivo evaluar la consistencia de los modelos GARCH, para modelar y predecir la “volatilidad en el sector del petróleo de baja calidad y alto contenido de azufre, así como su utilidad para la identificación de las principales características de la heterocedasticidad condicional”.

Tsakou (2016) Sus resultados en el estudio de las rentabilidades de los índices bursátiles estadounidenses y europeos, encontraron que la media de los retornos es constante y alrededor de cero, pero la varianza cambia con el tiempo mostrando evidencia de agrupación de volatilidad.

So (2016) sostiene que la literatura de finanzas demuestra claramente que los datos de las series temporales financieras muestran autocorrelación, heteroscedasticidad, agrupación de la volatilidad y efectos de apalancamiento.

4.4.3 Los niveles de noticias influyen directamente en el tipo de asimetría de la volatilidad de los retornos de las acciones

Tal como se corroboró en las siguientes investigaciones de:

García (2014) quien sostiene que "los rendimientos financieros presentan con frecuencia una relación compleja con observaciones previas, así como una ligera asimetría como consecuencia, propone utilizar modelos más flexibles que sean capaces de asir estos rasgos especiales". Agrega que un proceso GARCH simultáneamente captura la asimetría y colas pesadas.

Hossain, Kamruzzaman y Ali (2015) observan que los modelos de EGARCH que capturan la asimetría de los retornos, son tranquilamente razonables

De Jesús, Vergara, y Díaz (2015), sus hallazgos muestran la presencia de apalancamiento en el mercado del petróleo de la Mezcla Mexicana de Exportación debido a que las malas noticias tienen mayor impacto en la volatilidad que las malas noticias de la misma magnitud.

Tsakou (2016) encontraron que en los modelos GJR y GJR-IV, $\alpha_1 + \gamma > 0$ para todos los índices que indican que las malas noticias aumentan la volatilidad condicional más que las buenas noticias α_1. Agregan posteriormente la evidencia de que hay efectos asimétricos contemporáneos para todas las estimaciones y los rendimientos negativos influyen en los índices de volatilidad implícitos más que en los retornos positivos.

4.4.4 Los valores extremos de los retornos, genera series leptocúrticas y colas anchas

Se hallaron similitudes con los siguientes trabajos de investigación:

Herrera (2013) tomó una muestra de 2,700 series temporales, 32,400 datos, y en su resultado exponen "la propuesta genera razonablemente realizaciones que reproducen las características de la serie"; en los resultados encontraron series leptocúrticas.

Oliver (2013) En sus resultados muestra que “la propuesta genera razonablemente realizaciones que reproducen las características de la serie, particularmente para el caso de valores mínimos extremos, representando una mejora y el uso de casos multidimensionales y de grados superiores genera series leptocúrticas”.

García (2014) sostiene que los retornos financieros frecuentemente presentan relaciones complejas con observaciones pasadas, una ligera asimetría y alta curtosis. En los resultados de su trabajo se realizó comparaciones entre el modelo econométrico EGARCH que fue el modelo que mejor recogió la asimetría de las volatilidades.

Tsakou (2016) Corrobora para los valores de curtosis de una distribución normal, igual a tres. En los resultados de los rendimientos del mercado de valores, las estadísticas de curtosis muestran la característica leptocúrtica de todas las distribuciones de retornos.

So (2016), el investigador encuentra que los datos de las rentas financieras no están distribuidos normalmente contra el supuesto clásico de la distribución normal. Para estas situaciones desarrolla modelos GARCH para pronosticar y capturar hechos comunes sobre volatilidad condicional (por ejemplo, colas gordas, persistencia de volatilidad y agrupación, asimetría y efectos de apalancamiento).

CONCLUSIONES

1. El primer paso para modelar series de tiempo, es necesario se cumpla la condición de estacionariedad que es la diferenciación de los precios de cierre de un activo financiero.

2. El primer momento de la distribución de probabilidad es igual a cero y tiene un rendimiento constante a lo largo del tiempo debido a que cumple la condición de estacionariedad.

3. El segundo momento de la distribución de probabilidad, muestra que la varianza no es constante u homocedástica a lo largo del tiempo, es decir que es heterocedástica.

4. El tercer momento de la distribución de probabilidad, muestra un comportamiento asimétrico, debido al impacto del tipo de noticias negativas la volatilidad será mayor la volatilidad que cuando se presentan noticias positivas.

5. El cuarto momento de la distribución es leptocúrtica o tiene exceso de curtosis pues tiene una alta concentración alrededor de los valores esperados y la cola de sus extremos son muy angostas y por tanto hay alta probabilidad de tener eventos catastróficos o extremos.

6. Los errores de pronóstico dentro de muestra, señalan que no existe diferencias significativas entre los pronósticos de las Redes neuronales probabilísticas/ regresión generalizada, con las del modelo TGarch.

7. Los resultados fuera de muestra muestran que los pronósticos con redes neuronales son ligeramente mayores comparados con los otros modelos.

RECOMENDACIONES

1. Pronosticar con los modelos de series de tiempo debido a que producen mejores resultados que los modelos estructurales. Estos modelos son muy utilizados en finanzas por sus buenos resultados.
2. En teorías estadísticas y econométricas de series de tiempo, trabajar con los métodos basados en la metodología de Box y Jenkins o ARIMA.
3. Utilizar la metodología Box y Jenkins o ARIMA, para eliminar la tendencia que presenta un instrumento financiero, diferenciando su serie original hasta convertirla en estacionaria.
4. Verificar que una serie sea estacionaria y su media sea igual a cero, no debe estar correlacionadas. y que no tener ruido blanco, vale decir que tenga memoria para posibilitar su pronóstico.
5. Comprobar que los errores de una serie tengan ruido blanco pues representan un paseo aleatorio cuyos cambios son imprevisibles. La característica fundamental de este proceso es la falta de afinidad de las series a una media estable.
6. Verificar que la varianza de la volatilidad sea homocedástica para ser modelado con la metodología Box y Jenkins caso contraria deberá ser modelado con GARCH.
7. Utilizar el modelo TGarch para comportamientos asimétricos a consecuencia del impacto del tipo de noticia.
8. Utilizar el modelo TGarch en situaciones de valores extremos.
9. Hacer predicciones a corto plazo por son más interesantes las medias y las varianzas condicionales a la información pasada que las medias y las varianzas no condicionales o pronósticos a largo plazo.
10. Utilizar técnicas de combinación de pronóstico con redes neuronales artificiales del campo de la inteligencia artificial

REFERENCIAS BIBLIOGRAFICAS

Álvarez-Pallete, J. (2018, 14 de mayo). [Carta a nuestros accionistas: El ilusionante reto de reinventar Telefónica]. Copia en posesión de Wilfredo Bazán.

Bello, M. (mayo de 2017). *4.Econometría financiera-Series de tiempo D*. Medición de riesgos en la toma de decisiones con el apoyo de Risk Simulator. Software-Shop, Lima.

Bello, M. (mayo de 2017). *Modelos Arch y Garch*. Medición de riesgos en la toma de decisiones con el apoyo de Risk Simulator. Software-Shop, Lima.

Bello, M. (mayo de 2017). *Pronósticos*. Medición de riesgos en la toma de decisiones con el apoyo de Risk Simulator. Software-Shop, Lima.

Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics 31*, 307-327.

Bollerslev, T. (2008). Glossary to ARCH (GARCH). CREATES Research Paper 2008-49. Available at SSRN: http://ssrn.com/abstract=1263250. En: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=1263250. Leído el 15/07/2012.

Box, G., Jenkins, G. y Reinsel, G. (2008) *Time Series Analysis: Forecasting and Control*. New York: John Wiley & Sons, Fourth Edition.

Bunge, M. (2012). *Filosofía de la tecnología y otros ensayos*. Lima: Fondo Editorial de la UIGV.

Bunge, M. (2009). *¿Qué es filosofar científicamente? y otros ensayos*. Lima: Fondo Editorial de la UIGV.

Court, E. y Rengifo, E. (2011). *Estadística y Econometría Financiera*. Buenos Aires: Cengage Learning Argentina.

Chung, A. (2016). Apuntes de clase de Unidad 1*: Investigación Científica*. UPG - UNMSM, Lima.

Chung, S. (2014). *A Class of Semiparametric Volatility Models with Applications to Financial Time Series* (tesis doctoral). Florida State University, Florida State.

Damodar, G. y Porter, D. (2010). *Econometría*. México D.F.: Mc Graw-Hill/Interamericana Editores, S.A. de C.V.

De Jesús, R., Vergara, R. y Díaz, M. (2015). *Predicción de la volatilidad en el mercado del petróleo mexicano ante la presencia de efectos asimétricos*. Cuadernos de Economía, vol. XXXIV, núm. 65, julio-diciembre, 2015, pp. 299-326.

De La Cruz, C. (Productor). (24 de julio del 2018) *Pronóstico de Ventas usando Redes Neuronales* [Vídeo en webcast]. Recuperado de https://youtu.be/MLoNQwAD_YE

EFE, A. (*9 de* octubre de 2018). *Yahoo! Finanzas*. Recuperado de https://es.finance.yahoo.com/noticias/caixabank-explica-salida-repsol-justifica-113100912.html

García, C. (2014). *Modeling Financial Returns with Skew-Slash Innovations* (tesis doctoral). Universidad Carlos III de Madrid, Madrid.

Girón, L. (2018). Econometría aplicada: Usando Eviews 10.0. Santiago de Cali. Editorial Javeriano.

Glosten, L., Jagannathan, R. y Runkle, D. (1993). On the Relation Between the Expected Value and the Volatility of the Normal Excees Return on Stocks. *Journal of Finance, 48*.

Guevara, C. (2018). Apuntes de clase de *Semana 6 - Sesión 1: Econometría Financiera*. Macroeconometría aplicada con Eviews. Infopuc - PUCP, Lima.

Gujarati, D. y Porter, D. (2010). *Econometría*. México D.F.: Mc Graw-Hill/Interamericana Editores, S.A. de C.V.

Hanke, J. y Wichern, D. (2010). P*ronósticos en los negocios*. Estado de México: Pearson Educación de México, S.A. de C.V.

Herrera, J. (2013). *Modelo Estocástico a partir de Razonamiento Basado en Casos para la Generación de Series Temporales* (tesis doctoral). Universidad Nacional de San Agustín, Arequipa.

Hernández, R. y Mendoza, P. (2018). *Metodología de la investigación. Las rutas cuantitativa, cualitativa y mixta*. México D.F.: Mc Graw-Hill/Interamericana Editores, S.A. de C.V.

Hossain, A., Kamruzzaman y Ali, A. (2015). *ARIMA With GARCH Family Modeling and Projection on Share Volume of DSE*. Economics World, August 2015, Vol. 3, No. 7-8, 171-184.

Jauregui, J. (Productor). (31 de diciembre del 2017) *Cálculo de la Volatilidad del precio de Acciones Usando Modelos GARCH en EViews 8* [Vídeo en webcast]. Recuperado de https://www.software-shop.com/contenido/video/2226

Larios, J. Álvarez, V. y González, C. (2016). *Investigación en economía y negocios: Metodología con aplicaciones en E-views.* Lima: Universidad San Ignacio de Loyola Fondo Editorial.

Meléndez, J. (junio de 2017). *Series de tiempo*. I Entrenamiento Especializado en Modelos Econométricos de Series de Tiempo en EViews. Software-Shop, Bogotá.

Mun, J. (2016). *Modelación de Riesgos*. California, EE.UU.: Thomson-Shore.

Newbold, P. Carlson, W, y Thorne, B. (2008). *Estadística para Administración y Economía***.** Madrid**:** Pearson Educación, S.A.

Ñaupas, H., Mejía, E., Novoa, E. y Villagomez, A. (2014). Metodología de la investigación cuantitativa-cualitativa y redacción de la tesis. Bogotá: Ediciones de la U.

Niño, M. (s/f). Metodología de la investigación y Fundamentos de Estadística. Edición de Kindle.

Oliver, J. (2013). *Modelación de la volatilidad condicional en índices bursátiles comparativa modelo Egarch versus red neuronal backpropagation* (tesis doctoral). Universitat Politécnica de València, Valencia.

Ortiz, F. (2017). *Pronóstico de precios de petróleo: una comparación entre modelos GARCH y redes neuronales diferenciales*. Recuperado de https://www.sciencedirect.com/science/article/pii/S0185166717300140

Parody, E., Charris, A. y García, R. (2016). *Modelo Log-normal para la Predicción del Precio de las Acciones del Sector Bancario que Cotizan en el Índice General de la Bolsa de Valores de Colombia (IGBC)*. Dimensión Empresarial, 14(1), 137 -149

Raffo, E. (2012). *Modelación y simulación con Simio.* Lima: Centro de Producciones Editoriales e Imprenta de la Universidad Mayor de San Marcos.

Ramón, N. y López, J. (2016). *Econometría: series temporales y modelos de ecuaciones simultáneas.* España: Editorial Universidad Miguel Hernández de Elche.

Salcedo, H. (2012). *Epistemología o filosofar sobre la ciencia.* Colombia: Unaula.

Sánchez, H. y Reyes, C. (2015). *Metodología y diseño de la investigación científica*. Lima: Business Support Anneth SRL

So, N. (2016). *Analysis of Risk Exposure in Korean Financial Markets: A Copula Approach*. University of Minnesota.

Telefónica (2010). *¿Sabe cómo funciona la bolsa?* Plan Global de Compra de

Acciones para Empleados de Telefónica. Documento interno.

Telefónica (2017). Presencia en bolsas. Madrid: Telefónica. Recuperado de https://www.telefonica.com/es/web/shareholders-investors/la_accion/presencia-en-bolsas

Trujillo, G. (2010). *Econometría con Eviews*. Cajamarca: Universidad Nacional de Cajamarca.

Tsakou, K. (2016). *Essays on Financial volatility forecasting.* (tesis doctoral). University of Stirling, Scotland UK.

Villalba, F. y Flores, M. (2014). Análisis de la volatilidad del índice principal del mercado bursátil mexicano, del índice de riesgo país y de la mezcla mexicana de exportación mediante un modelo GARCH trivariado asimétrico. *Revista de métodos cuantitativos para la economía y la empresa, 17*, 3-22.

Wooldridge, J. (2010). *Introducción a la econometría. Un enfoque moderno***.** Mexico, D.F.**:** Cengage Learning.

Yahoo.es (2017). *Yahoo! Finanzas*. Madrid: Yahoo. Recuperado de https://es.finance.yahoo.com/quote/TEF/history?p=TEF

Ynoub, R (2015). *Cuestión de método.* Mexico, D.F.**:** Cengage Learning.

ANEXOS

Anexo 1 **Precio de cierre de las acciones de TEF del 02/08/18 al 15/08/18 y el pronóstico con cinco modelos**

FECHA	Precio cierre TEF	Pronos. modelo Garch	Pronos. modelo Tgarch	Pronos. Redes Neuronales (NeuralTools)	Pronos. Redes Neuronales (Risk Simulator)	Pronos. con Suavizado Exponencial Doble
2/08/2018	7.5960	7.6621	7.6599	7.6593	7.6589	7.6609
3/08/2018	7.6220	7.6624	7.6585	7.6575	7.6568	7.6605
6/08/2018	7.6150	7.6663	7.6589	7.6558	7.6547	7.6601
7/08/2018	7.6560	7.6759	7.6675	7.6540	7.6526	7.6597
8/08/2018	7.6300	7.6725	7.6628	7.6523	7.6505	7.6592
9/08/2018	7.5940	7.6748	7.6613	7.6505	7.6484	7.6588
10/08/2018	7.4700	7.6797	7.6631	7.6488	7.6463	7.6584
13/08/2018	7.4530	7.6786	7.6608	7.6470	7.6442	7.6579
14/08/2018	7.4340	7.6810	7.6600	7.6453	7.6421	7.6575
15/08/2018	7.3720	7.6849	7.6607	7.6435	7.6400	7.6571

Fuente: Elaboración propia

Anexo 2 **Promedio de los errores al cuadrado y raíz del error cuadrático medio**

	Errores de pronóstico					Errores de pronóstico al cuadrado				
Fecha	**EP_Garch**	**EP_MGarch**	**EP_RN (NT)**	**EP_RN_RS**	**EP_AED**	**EP_Garch2**	**EP_MGarch2**	**EP_RN2**	**EP_RN_RS**	**EP_AED**
2/08/2018	-0.0661	-0.0639	-0.0633	-0.0629	-0.0649	0.0044	0.0041	0.0040	0.0040	0.0042
3/08/2018	-0.0404	-0.0365	-0.0355	-0.0348	-0.0385	0.0016	0.0013	0.0013	0.0012	0.0015
6/08/2018	-0.0513	-0.0439	-0.0408	-0.0397	-0.0451	0.0026	0.0019	0.0017	0.0016	0.0020
7/08/2018	-0.0199	-0.0115	0.0020	0.0034	-0.0037	0.0004	0.0001	0.0000	0.0000	0.0000
8/08/2018	-0.0425	-0.0328	-0.0223	-0.0205	-0.0292	0.0018	0.0011	0.0005	0.0004	0.0009
9/08/2018	-0.0808	-0.0673	-0.0565	-0.0544	-0.0648	0.0065	0.0045	0.0032	0.0030	0.0042
10/08/2018	-0.2097	-0.1931	-0.1788	-0.1763	-0.1884	0.0440	0.0373	0.0320	0.0311	0.0355
13/08/2018	-0.2256	-0.2078	-0.1940	-0.1912	-0.2049	0.0509	0.0432	0.0376	0.0366	0.0420
14/08/2018	-0.2470	-0.2260	-0.2113	-0.2081	-0.2235	0.0610	0.0511	0.0446	0.0433	0.0500
15/08/2018	-0.3129	-0.2887	-0.2715	-0.2680	-0.2851	0.0979	0.0833	0.0737	0.0718	0.0813
						0.0022	**0.0228**	**0.0199**	**0.0193**	**0.0222**
						MSE (promedio de los errores al cuadrado)				
						0.0466	**0.1510**	**0.1409**	**0.1389**	**0.1488**
						RMSE (raíz del error cuadrático medio)				

Fuente: Elaboración propia

Anexo 3 **MAD (desviación absoluta media) y MAPE (desviación absoluta porcentual media)**

	Errores de pronóstico absolutos					Errores porcentuales absolutos				
Fecha	**|EP_Garch|**	**|EP_Mgarch|**	**|EP_RN_NT|**	**|EP_RN_RS|**	**|EP_AED|**	**APE_Garch**	**APE_Mgarch**	**APE_RN**	**EP_RN_RS**	**EP_AED**
2/08/2018	0.0661	0.0639	0.0633	0.0629	0.0649	0.870%	0.842%	0.833%	0.828%	0.855%
3/08/2018	0.0404	0.0365	0.0355	0.0348	0.0385	0.531%	0.479%	0.466%	0.457%	0.505%
6/08/2018	0.0513	0.0439	0.0408	0.0397	0.0451	0.674%	0.577%	0.536%	0.521%	0.592%
7/08/2018	0.0199	0.0115	0.0020	0.0034	0.0037	0.260%	0.150%	0.026%	0.044%	0.048%
8/08/2018	0.0425	0.0328	0.0223	0.0205	0.0292	0.557%	0.430%	0.292%	0.269%	0.383%
9/08/2018	0.0808	0.0673	0.0565	0.0544	0.0648	1.064%	0.886%	0.744%	0.716%	0.853%
10/08/2018	0.2097	0.1931	0.1788	0.1763	0.1884	2.807%	2.585%	2.394%	2.360%	2.522%
13/08/2018	0.2256	0.2078	0.1940	0.1912	0.2049	3.027%	2.788%	2.603%	2.565%	2.750%
14/08/2018	0.2470	0.2260	0.2113	0.2081	0.2235	3.323%	3.040%	2.842%	2.799%	3.007%
15/08/2018	0.3129	0.2887	0.2715	0.2680	0.2851	4.244%	3.916%	3.683%	3.635%	3.867%
	0.1296	**0.1172**	**0.1076**	**0.1059**	**0.1148**	**1.736%**	**1.569%**	**1.442%**	**1.420%**	**1.538%**
	MAD (desviación absoluta media)					**MAPE (desviación absoluta porcentual media)**				

Fuente: Elaboración propia

Anexo 4 **MPE (error porcentual medio)**

	Errores porcentuales				
Fecha	**PE_Garch**	**PE_Mgarch**	**PE_RN**	**PE_RN_RS**	**PE_AED**
2/08/2018	-0.870%	-0.842%	-0.833%	-0.828%	-0.855%
3/08/2018	-0.531%	-0.479%	-0.466%	-0.457%	-0.505%
6/08/2018	-0.674%	-0.577%	-0.536%	-0.521%	-0.592%
7/08/2018	-0.260%	-0.150%	0.026%	0.044%	-0.048%
8/08/2018	-0.557%	-0.430%	-0.292%	-0.269%	-0.383%
9/08/2018	-1.064%	-0.886%	-0.744%	-0.716%	-0.853%
10/08/2018	-2.807%	-2.585%	-2.394%	-2.360%	-2.522%
13/08/2018	-3.027%	-2.788%	-2.603%	-2.565%	-2.750%
14/08/2018	-3.323%	-3.040%	-2.842%	-2.799%	-3.007%
15/08/2018	-4.244%	-3.916%	-3.683%	-3.635%	-3.867%
	-1.736%	**-1.569%**	**-1.437%**	**-1.411%**	**-1.538%**
	MPE (error porcentual medio)				

Fuente: Elaboración propia